



Universidad
Carlos III de Madrid

Departamento de Ingeniería Mecánica

INGENIERÍA INDUSTRIAL

PROYECTO FIN DE CARRERA

IDENTIFICACIÓN DEL ESTADO DE RODAMIENTOS DE BOLA MEDIANTE ANÁLISIS WAVELET Y MÁQUINAS DE SOPORTE VECTORIAL

Autor: Álvar Arroyo San Cristóbal

Tutor: Cristina Castejón Sisamón

Co-tutor: M^a Jesús Gómez García

Leganés, Junio de 2015

Agradecimientos

En primer lugar agradecer a mi tutora Cristina Castejón Sisamón por darme la oportunidad de realizar este proyecto y sobre todo, por su dedicación y ayuda, que me ha permitido aprender muchísimo. También agradecer a M^a Jesús Gómez García, por toda la ayuda que me ha brindado y al Departamento de Ingeniería mecánica por permitirme realizar el proyecto.

No me puedo olvidar de mis padres a la hora de agradecer, sin su apoyo y ayuda no hubiera sido capaz de llegar a la meta. También a mis abuelos, por ser mi modelo a seguir y por su confianza en mí.

A David, Javi, Damián y Dani, porque quedan atrás muchos momentos buenos y malos donde siempre tuve vuestro apoyo y ayuda.

Y por supuesto a Soraya, por su apoyo y confianza en mí.

A todos, Muchas Gracias.

Lista de siglas

AI.	“Artificial Intelligence”. Inteligencia Artificial.
BPFI.	“Ball Pass Frequency Inner race”. Frecuencia de paso de la bola por la pista interna.
BPFO.	“Ball Pass Frequency Outer race”. Frecuencia de paso de la bola por la pista externa.
BSF.	“Ball Spin Frequency”. Frecuencia de paso de algún defecto de la bola
CFF.	“Cage Fault Frequency” Frecuencia de fallo de la jaula.
CI.	“Computational Intelligence”. Inteligencia Computacional.
CWT.	“Continuous Wavelet Transform”. Transformada Wavelet Continua.
DFT.	“Discrete Fourier Transform”. Transformada Discreta de Fourier.
DWT.	“Discrete Wavelet Transform”. Transformada Wavelet Discreta.
FFT.	“Fast Fourier Transform”. Transformada Rápida de Fourier
FT.	“Fourier Transform”. Transformada de Fourier.
HT.	“Hilbert Transformation”. Transformada de Hilbert
MRA.	“Multiresolution Analysis”. Análisis Multirresolución.
PFC.	Proyecto Fin de Carrera.
PSD.	“Power Spectral Density”. Potencia spectral.
QMF.	“Quadrature Mirror Filters”. Filtros Espejo en Cuadratura.
RBF.	“Radial Basis Function”. Función de base Radial.
STFT.	“Short-time Fourier Transform”. Transformada de Fourier con ventaneado.
SVM.	“Supported Vector Machine”. Máquinas de Soporte Vectorial
WPT.	“Wavelet Packet Transform”. Transformada en Paquetes Wavelet
WT.	“Wavelet Transform”. Transformada Wavelet
1-vs-1.	“One versus one”. Uno Contra Uno.
1-vs-r.	“One versus rest”. Uno Contra el Resto.

Índice

Agradecimientos.....	iii
Lista de Siglas.....	v
1. Introducción	1
1.1.Motivación	1
1.2.Objetivos del proyecto.....	2
1.3.Estructura del documento.....	3
2. Introducción al mantenimiento Industrial.....	5
2.1.Monitorización de estado en elementos rotativos.....	7
2.1.1. Orígenes y usos.....	7
2.1.2. Procedimiento para la monitorización de estado	8
y justificación de uso	
2.1.3. Tendencias actuales en el uso de monitorización de.....	8
estado en procesos industriales	
2.2.Teoría sobre Tratamiento de señales.....	9
2.2.1. Transformada de Fourier.....	10
2.2.2. Envoltente de la señal.....	12
2.2.3. La Transformada Wavelet.....	13
2.3.Sistemas de clasificación inteligentes.....	23
2.3.1. Introducción a los sistemas de clasificación inteligentes.....	23
2.3.2. Inteligencia artificial computacional.....	24
2.3.3. Máquinas de soporte vectorial.....	27
3. Desarrollo del proyecto. Adquisición y análisis de señales.....	40
3.1.Adquisición.....	40
3.1.1. Procedimiento para la toma de datos en banco de ensayo.....	40
3.1.2. Banco de ensayos y componentes.....	41
3.2.Análisis de las señales.....	42
3.2.1. Introducción a las frecuencias características de fallo de los.....	43
rodamientos	
3.2.2. Análisis en frecuencia de señales. Búsqueda de la frecuencia	45
característica de fallo	
3.2.3. Análisis en tiempo-frecuencia de señales. Uso de la.....	51
transformada de paquetes wavelet (WPT)	
3.2.4. Selección del nivel de descomposición para el análisis.....	51
de energía en los paquetes wavelet	
4. Sistema de clasificación y resultados.....	56
4.1.Máquinas de soporte vectorial. Tipos de clasificación multiclase.....	56
4.1.1. Clasificación multiclase 1-vs-r.....	56
4.1.2. Clasificación multiclase 1-vs-1.....	57
4.2.Sistema de clasificación.....	59

4.2.1. Clasificación uno contra el resto.....	59
4.2.2. Clasificación uno contra uno.....	65
4.3. Determinación del tamaño mínimo de datos representativo.....	70
para la clasificación	
4.4. Pruebas de robustez del método.....	73
4.4.1. Prueba de robustez. Clasificación 1-vs-r.....	74
4.4.2. Prueba de robustez. Clasificación 1-vs-1.....	75
5. Aplicación a defectos incipientes.	80
5.1. Análisis para velocidad de giro de 600 rpm.....	80
5.2. Análisis para velocidad de giro de 1200 rpm.....	81
5.3. Análisis para velocidad de giro de 1800 rpm.....	81
5.4. Análisis de los resultados.....	83
6. Conclusiones y futuros desarrollos.....	85
6.1. Conclusiones específicas.....	85
6.2. Futuros desarrollos.....	89
7. Bibliografía	91
8. Anexos.....	94
8.1. Anexo 1	94
8.2. Anexo 2	98
8.3. Anexo 3.....	109
8.4. Anexo 4.....	112
8.5. Anexo 5.....	121

1. Introducción

1.1. Motivación

En cualquier proceso industrial se persiguen varios objetivos: producir con la mayor calidad, reducir los ratios de productos no válidos y cumplir con unas normas de seguridad y de medio ambiente que cada vez son más estrictas.

Las operaciones de producción están sometidas a un cambio continuo en la persecución de estos objetivos y por ello muchas de las operaciones que en su momento fueron consideradas aceptables o adecuadas, no lo son por mucho tiempo.

Para conseguir que los productos sean de la mayor calidad posible, los procesos industriales modernos contienen un gran número de variables operativas bajo control. Los encargados de recopilar y analizar estas variables son los controladores de procesos (PID, controladores predictivos, etc.) que están diseñados para mantener satisfactoriamente las operaciones por medio de reacciones a los efectos producidos, ya sea por desviaciones o por cambios que ocurren durante la fabricación o el proceso. Estos controladores pueden compensar muchos tipos de desviaciones, pero hay cambios en el proceso que no pueden ser manejados correctamente por los mismos.

Estos cambios son los denominados fallos o defectos. Para ser más precisos, un defecto se define como una desviación no permitida de al menos una de las propiedades características o variable del sistema.

Para asegurarnos que las operaciones del proceso satisfacen las especificaciones de rendimiento, los fallos o defectos en el proceso necesitan ser detectados, analizados y reparados.

En el presente proyecto nos centraremos tanto en la detección como en el análisis de los defectos en rodamientos de bola, por ser los elementos de apoyo más comunes en maquinaria industrial y cuya misión además de reducir la fricción y soportar el eje, es la de ejercer de fusible mecánico. El hecho de que ejerzan este papel es fundamental para entender las razones que nos llevan a realizar este tipo de estudios puesto que el rendimiento de una máquina industrial depende directamente del número de paradas que deba realizar y del número de piezas defectuosas que fabrique, por lo que es necesario un correcto estado de los rodamientos para que ambos factores disminuyan todo lo posible. En el caso más desfavorable, si en un rodamiento se llegara a formar un defecto que lo colapse, podría hacer parar la producción e incluso romper otros elementos de la máquina mucho más caros y difíciles de reparar.

La motivación de este proyecto es conseguir un diagnóstico del estado del rodamiento mediante la adquisición, tratamiento y la posterior clasificación de las señales obtenidas de la máquina, teniendo en cuenta tanto los posibles tipos de defecto que pueda tener como la gravedad de los mismos.

1.2. Objetivos del proyecto

El desarrollo de este proyecto se centra en dos objetivos principales: el análisis de señales mediante técnicas que trabajan en el dominio de tiempo-frecuencia y el uso de las máquinas de soporte vectorial como técnica de clasificación para el diagnóstico de rodamientos de bola.

Dentro de los dos grandes objetivos, encontramos numerosos objetivos específicos que se detallarán a continuación:

- Trabajo con datos obtenidos en ensayos experimentales representativos
- Realización del análisis en frecuencia de la señal mediante la transformada de Fourier
- Identificación de las frecuencias características de defecto tanto de forma teórica como práctica mediante la transformada de Fourier
- Uso de la envolvente de la señal mediante la transformada de Hilbert como método para la eliminación de ruido
- Análisis de la posibilidad de realizar la identificación de la condición del rodamiento mediante técnicas basadas en el dominio de la frecuencia (Transformada de Fourier y Transformada de Hilbert)
- Análisis de la señal de vibración mediante técnicas que combinan el dominio del tiempo y la frecuencia (Transformada Wavelet)
- Descomposición de la señal en paquetes Wavelet para la extracción de los coeficientes de energía
- Generación de los vectores característicos en función de los coeficientes de energía para cada condición de estudio y búsqueda de las condiciones óptimas
- Clasificación de las señales vibratorias en función de sus vectores característicos utilizando máquinas de soporte vectorial
- Uso de los métodos, uno contra uno y uno contra el resto para la realización de la clasificación multiclase
- Búsqueda de las condiciones óptimas de entrenamiento y clasificación mediante la modificación de los parámetros de margen blando y función soporte
- Búsqueda de las condiciones óptimas de entrenamiento y clasificación mediante la modificación del número de vectores característicos que utilizamos para entrenar la máquina de vectores soporte
- Búsqueda de las condiciones óptimas de entrenamiento y clasificación mediante la modificación del número de datos de la señal necesario para conseguir resultados aceptables
- Adición de ruido a la señal para comprobar la robustez del método
- Uso de señales de vibración recogidas en un medio menos aislado que el utilizado en el resto de apartados para comprobar la robustez del método

Para la realización del proyecto, se hace uso del entorno de MATLAB® tanto para el tratamiento de señales como para su posterior clasificación. Para las máquinas de

soporte vectorial se utiliza la librería específica Libsvm obtenida de [26]. Para el tratamiento de señales utilizando la FFT y la HT se utilizan las librerías internas de MATLAB®.

1.3. Estructura del documento

El documento está dividido en seis capítulos en los cuales se detalla lo siguiente:

En el capítulo 1, se relata la motivación del proyecto fin de carrera, se enumeran los objetivos a perseguir y se describe la estructura del documento.

En el capítulo 2, se hace una breve introducción al mantenimiento industrial, tipos de mantenimiento y su evolución. Por otro lado se desarrolla el estado del arte sobre la monitorización de estado en elementos rotativos, además de introducir teóricamente los métodos de análisis de señales en el dominio de la frecuencia como son la transformada de Fourier y la transformada de Hilbert. También se hará referencia a la transformada Wavelet y a la descomposición en paquetes Wavelet y al método de clasificación por vectores soporte (SVM).

En el capítulo 3, se expondrá parte del desarrollo del proyecto, donde se especificará todo lo relativo a la adquisición de los datos y a la metodología empleada para el tratamiento de la señal de vibración, desde la selección de los datos hasta la generación de los vectores característicos para su posterior clasificación.

En el capítulo 4, se tratará en profundidad el sistema de clasificación, detallando la metodología empleada y se resumen los resultados obtenidos a partir de la clasificación de los vectores característicos generados en el capítulo 3.

En el capítulo 5, se emplearán los mejores métodos utilizados en los capítulos 3 y 4 para analizar señales de defectos incipientes.

En el capítulo 6 se analizarán los resultados obtenidos en los capítulos 4 y 5, extrayendo las conclusiones pertinentes además del planteamiento de futuros desarrollos de la metodología empleada.

2. Introducción al mantenimiento industrial

Para la consecución de los objetivos de cualquier proceso industrial, es necesario manejar correctamente los fallos o defectos que aparecen en las máquinas industriales. Es por ello que el mantenimiento industrial cobra una gran importancia y cada vez se invierte más dinero y recursos tanto en su ejecución como en su desarrollo e innovación.

El mantenimiento industrial podríamos definirlo como el control constante de las instalaciones y/o componentes, así como del conjunto de trabajos de reparación y revisión necesarios para garantizar el funcionamiento regular y el buen estado de conservación de las máquinas.

Dentro de la multitud de objetivos que se persiguen aplicando un buen mantenimiento, pueden destacarse las siguientes:

- Evitar, reducir y , en su caso, reparar los fallos
- Disminuir la gravedad de los fallos que no se puedan evitar
- Evitar detenciones inútiles o paros de la máquina
- Evitar accidentes
- Conservar los bienes productivos en condiciones seguras de operación
- Reducir costes
- Prolongar la vida útil de los bienes

Por supuesto, no siempre se han aplicado las mismas técnicas de mantenimiento ni siquiera la misma filosofía puesto que la tecnología evoluciona y con ella las técnicas de mantenimiento.

Durante el desarrollo de la industria, la filosofía de mantenimiento pasó en primer lugar por un mantenimiento correctivo, el cual, comprende el conjunto de actividades destinadas a la sustitución o reparación de elementos deteriorados que se realiza una vez que aparece el fallo o defecto. Este tipo de mantenimiento tiene dos enfoques: El llamado paliativo o de campo, que consiste en la reposición del funcionamiento aunque no se determine lo que produjo el fallo, y el mantenimiento curativo o de reparación que consiste en la reparación del fallo [3, 5, 25, 30].

La evolución de esta filosofía de mantenimiento fue el mantenimiento preventivo y surge de la necesidad de reducir la frecuencia y el impacto de los fallos. Se pretende reducir la reparación mediante una rutina de inspecciones periódicas y la renovación de los elemento dañados [3, 5, 25, 30]. Con este tipo de mantenimiento nos encontramos inconvenientes como:

- Cambios innecesarios de un elemento que todavía funciona pero que se cambia por precaución
- Problemas iniciales de operación
- Necesidad de mano de obra

- Aumento de costes por inventario. Se sustituirán más piezas que si sólo las cambiamos cuando rompen

Hoy en día es de vital importancia la mantenibilidad de un sistema mecánico, entendiendo ésta como la capacidad o viabilidad de un sistema mecánico de ser mantenido con la menor duración, coste y esfuerzo de las tareas de mantenimiento [13].

Por ello, la evolución lógica del mantenimiento preventivo es el mantenimiento predictivo o también conocido como monitorización de estado (en inglés *condition monitoring*). Este tipo de mantenimiento se basa en predecir el fallo o defecto antes de que éste se produzca, además de controlar el estado de funcionamiento en cada momento de la máquina. Se trata de adelantarse a que se produzca el defecto o al momento en que el equipo o elemento deja de trabajar en las condiciones óptimas de funcionamiento. Para ello se utilizan herramientas y técnicas de monitorización generalmente de parámetros físicos como la presión, la temperatura, vibraciones, etc. [3, 5, 25, 27, 28, 29, 30].

El esquema general correspondiente a la gestión de un sistema de mantenimiento predictivo se muestra en la figura 2.1.

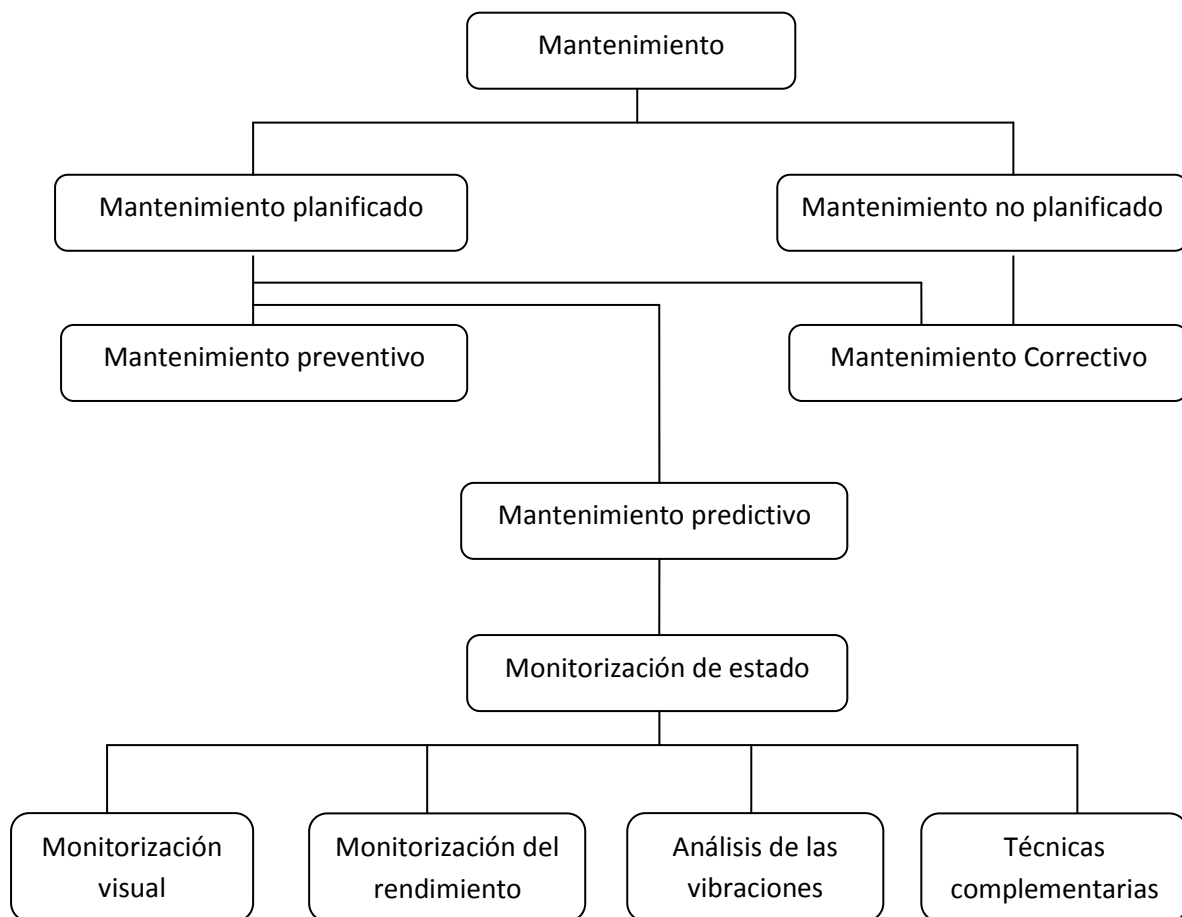


Figura 2.1. Esquema general de la gestión de un sistema de mantenimiento predictivo [25].

Las técnicas más utilizadas hoy en día para monitorizar el estado de una máquina son la inspección visual y sonora, análisis de lubricantes, ultrasonidos, termografías,

videoscopia, medidas de temperatura, análisis de impulsos de choque y análisis de vibraciones entre otros [28].

El presente PFC se enmarca en el ámbito del mantenimiento predictivo, centrándonos en los rodamientos de bola por ser uno de los elementos más comunes en las máquinas rotativas y debido a que su misión es la de actuar como fusible mecánico, es de vital importancia conocer su estado y poder prever cuando reemplazarlo.

2.1. Monitorización de estado en elementos rotativos

2.1.1. Orígenes y usos

La monitorización del estado de funcionamiento es uno de los pilares del mantenimiento predictivo puesto que le aporta toda la información necesaria para que la toma de decisiones en la planificación del mantenimiento sean las mejores posibles.

En los inicios, esta técnica no podía ser aplicada a todo tipo de máquinas ni en todas las condiciones posibles de funcionamiento, excluyendo por ejemplo las máquinas con velocidades de funcionamiento bajas así como las líneas de proceso continuo especialmente complejas. Además, esta tarea de seguimiento era realizada de forma manual por expertos en la materia, a través de rondas rutinarias que llevaban a un aumento en los costes de personal y a una diferencia de criterios entre expertos.

Sin embargo, la evolución de los sensores y su reducción de coste así como la aparición de sistemas de control automáticos han dado pie al impulso de soluciones automáticas y el uso de técnicas de análisis de vibraciones en máquinas cuyas velocidades son del orden de hasta 6 rpm [25].

Estos avances han permitido que la aplicación de la monitorización del estado de funcionamiento se extienda a cualquier tipo máquina, no sólo a aquellas a las que podríamos denominar críticas (pensemos por ejemplo en turbinas) sino que se extiende a otras que podríamos denominar no críticas como compresores, bombas o ventiladores cuyo estado de funcionamiento es de gran utilidad conocerlo para la toma de decisiones en la planificación del mantenimiento [27]. Con todo ello conseguimos al final una mayor visibilidad sobre la fiabilidad global de todas las máquinas involucradas en un proceso industrial.

2.1.2. Procedimiento para la monitorización de estado y justificación de uso

Para la representación del funcionamiento de una máquina rotativa mediante la adquisición de su señal vibratoria se necesita un gran número de datos. Este procedimiento necesita de un procesamiento que deberá ser elegido de manera que aumente la manejabilidad de la información y a su vez, sea capaz de extraer las características relevantes de las señales que permitan conocer el estado real de la máquina. A este tratamiento de la señal se le denomina extracción de patrones.

El fin de la extracción de patrones es el de comparar los indicadores clave de medida de la señal en cuestión, con los valores del comportamiento normal para determinar si hay alguna degradación del estado del equipo. Esta operación de comparación de señales consiste en recopilar, procesar y analizar las señales para proporcionar una imagen completa del estado de funcionamiento de la máquina.

La justificación de implementar una solución de monitorización a pesar de sus costes es fácil al tener en cuenta los numerosos beneficios que obtenemos. El más importante de todos ellos es que conseguimos el máximo tiempo de funcionamiento posible, además de una eficiencia óptima de la maquinaria y por lo tanto, un aumento de los ingresos. Además, se consigue una disminución de los gastos al garantizar el máximo rendimiento y conseguir una reducción de deshechos y un mejor uso de las materias primas al mismo tiempo que se puede incrementar la calidad del producto.

Otros dos aspectos en los que ejerce una gran repercusión la introducción de la monitorización de estado son la seguridad y la optimización de la fuerza laboral.

En el caso de la seguridad, mediante la supervisión de diversos parámetros de rendimiento, el sistema de monitorización puede ayudar a advertir de la inminencia del riesgo de fallos y ayudar a evitar lesiones.

En cuanto a la fuerza laboral, proporciona las herramientas para su optimización puesto que las rondas de diagnósticos manuales son extremadamente lentas y requieren de mucho tiempo de preparación dejando mucho menos tiempo para que los especialistas puedan analizar y evaluar los datos. El objetivo final en este aspecto es que el personal especializado esté dedicado el máximo tiempo posible a las tareas de mayor valor.

2.1.3. Tendencias actuales en el uso de monitorización de estado en procesos industriales

La tendencia actual al utilizar este tipo de sistemas es la de conocer en cada momento el estado de la máquina y no esperar a detectar un defecto para realizar su análisis. Por ello, pasamos a un esquema donde no se recopila información sino que

directamente según se recoge la información se procesa, buscando información relevante del estado de los componentes en estudio.

Posteriormente, lo que necesitamos es saber cuánto se desvía respecto a sus condiciones normales de funcionamiento y se hace uso de sistemas de clasificación previamente entrenados que son capaces de clasificar la información que les llega, una vez procesada, de manera que obtenemos el estado dinámico del sistema de manera permanente.

Utilizando estos sistemas de clasificación, conseguimos diagnosticar en cada momento la condición de los componentes y podemos ver con la suficiente antelación el paso de un estado sin defecto a otro estado con defecto pudiendo tomar las medidas necesarias.

2.2. Teoría sobre tratamiento de señales

Como ya hemos tratado en los apartados anteriores, el tratamiento de las señales tiene como fin obtener información relevante para la evaluación del estado dinámico del sistema. Cuando el estado de un elemento mecánico se deteriora, la señal varía en función del tipo de componente y del tipo de deterioro que sufra. Por poner un ejemplo práctico que se desarrollará en profundidad en el capítulo 3, en un rodamiento, según el tipo de defecto que nos encontremos (defecto en pista interna, externa, en bola o en la jaula), su señal cambia obteniéndose picos en frecuencias que dependen de la geometría del rodamiento.

Para el tratamiento de las señales se han empleado diversas técnicas que trabajan en el dominio del tiempo, en el dominio de la frecuencia o las técnicas más modernas que trabajan en ambos dominios a la vez.

La mayoría de los tratamientos de señales están realizados en el dominio de la frecuencia puesto que los métodos aplicados en el dominio del tiempo se basan en métodos estadísticos que arrojan poca información relevante por sí solos y habitualmente los fenómenos físicos relacionados con las vibraciones que aparecen debido a desperfectos en la máquina presentan propiedades periódicas.

Este tipo de estudios se realizan mediante el análisis de los picos de frecuencia, en los que la amplitud se ve modificada o en aquellos en que se ven desplazados por la presencia de un defecto.

Una gran parte de los métodos aplicados en el dominio de la frecuencia son herramientas basadas en los métodos de Fourier que se exponen a continuación.

2.2.1. Transformada de Fourier

La transformada de Fourier $X(f)$ de una señal continua en el dominio del tiempo se puede escribir como en la ecuación 2.1 [2]:

$$X(f) = \int_{-\infty}^{\infty} x(t) \cdot e^{-j2\pi ft} \cdot dt \quad (2.1)$$

o la transformada inversa como en la ecuación 2.2:

$$x(t) = \frac{1}{2 \cdot \pi} \cdot \int_{-\infty}^{\infty} X(f) \cdot e^{-j2\pi ft} \cdot df \quad (2.2)$$

Que simbólicamente expresamos de la siguiente forma:

$$x(t) \leftrightarrow X(f)$$

Siendo $x(t)$ y $X(f)$ un par de transformada de Fourier, con x en el dominio del tiempo y X en el dominio de la frecuencia.

Este método nos muestra las componentes en frecuencia de una señal que denominamos espectro continuo de $x(t)$. El propósito es sintetizar la señal como suma de funciones armónicas.

Para la resolución de este tipo de ecuaciones computacionalmente, nos encontramos con el problema del dominio continuo del tiempo y de la frecuencia, lo que nos supone no poder aplicar la Transformada de Fourier directamente. Cualquier computadora es únicamente capaz de hacer cálculos discretos y las ecuaciones asociadas a la FT toman infinitos valores en cualquier intervalo.

Debido a esta serie de dificultades se hizo necesaria la adaptación de las ecuaciones de la FT para ser manejadas por computadoras mediante su discretización. De aquí surge la Transformada Discreta de Fourier o DFT (del inglés, *Discrete Fourier Transform*) que obtenemos mediante la ecuación 2.3:

$$X(k) = \sum_{i=0}^{i=N-1} x(i) \cdot e^{-j2\pi ki} \quad (2.3)$$

No en todas las condiciones conseguimos que la DFT sea una aproximación suficiente a la FT puesto que durante el muestreo, truncado y la convolución necesarias para alcanzar su expresión como señal discreta pueden significar una pérdida o distorsión de la información que contiene la señal continua. Tomar algunas precauciones como delimitar la señal en frecuencia o que el número de muestras sea potencia de dos, ayuda a que la aproximación sea lo mejor posible.

La DFT sirvió como punto de partida para la resolución de este tipo de ecuaciones computacionalmente y que concluye con algoritmos de cálculo que permiten realizar este tipo de análisis con un número de operaciones mucho menor y consecuentemente se reduce el tiempo de cómputo. Este tipo de algoritmos se engloban en la Transformada rápida de Fourier o FFT y se debe recalcar que no sólo reduce el tiempo de cálculo sino que es capaz de reducir los errores de redondeo que se producen en la DFT optimizando tanto los cálculos necesarios para la resolución de la DFT como el error de redondeo que se comete en un factor de $(\log_2 N)/N$.




Figura 2.2. Comparación entre FFT Y DFT en número de operaciones necesarias

Es ésta mejora en tiempos de cómputo y el desarrollo de los procesadores lo que ha impulsado que se empezasen a realizar análisis en frecuencia de señales en tiempo real.

Hemos de tener en cuenta que no sólo nos encontramos con el problema del cálculo discreto en la transformada de Fourier, sino que otro de los inconvenientes o limitaciones que tiene este método es el hecho de que sólo conseguimos resultados satisfactorios en el caso de señales estacionarias, periódicas y suficientemente regulares, pero en el caso de señales no estacionarias el resultado puede no ser lo suficientemente bueno.

Este efecto se debe a que la función a descomponer es dependiente del tiempo y las funciones de Fourier son infinitas en el tiempo pero locales en frecuencia, de

manera que la FT puede detectar la presencia de una determinada frecuencia pero no darnos información sobre si sufre alguna variación a lo largo del tiempo. Por ello para casos de señales no estacionarias se empezó a utilizar la Transformada de Fourier con Ventaneado o STFT (del inglés, *Short-Time Fourier Transform*) y posteriormente el análisis Wavelet.

2.2.2. Envolvente de la señal

El uso de esta técnica para el análisis de señales radica en la posibilidad de mejorar la visualización de cambios en la amplitud de la señal en frecuencia que mediante otras técnicas pudieran quedar enmascarados por ruido o por otros elementos cuya vibración es de mayor energía.

En el caso de defectos en rodamiento, nos encontramos en un caso donde el uso de la transformada de Fourier para la detección de defectos es complicada puesto que las vibraciones que se producen al pasar por el defecto son de baja energía y posibilitan que si los datos recogidos tienen ruido es muy posible no poder diferenciar dicho defecto en el espectro de la señal. Por otra parte, el uso de técnicas como PSD (del inglés, *Power Spectral Density*) tiene el mismo inconveniente puesto que los altos niveles de vibración y energía de otros elementos pueden atenuar las vibraciones generadas por un defecto por lo que pueden quedar ocultas.

La envolvente de la señal se obtiene uniendo todos los máximos de la señal de manera que obtengamos el contorno del semiciclo positivo. Un ejemplo de ello se muestra en la figura 2.3.




Figura 2.3. Envolvente de la señal

Para la obtención de la envolvente de la señal podemos utilizar dos métodos: uno consiste en la técnica de rectificación – filtrado, donde aplicando un filtro paso banda, un rectificador y un filtro paso bajo conseguimos la envolvente. El otro es la técnica que aplica la transformada de Hilbert.

Transformada de Hilbert

La Transformada de Hilbert (HT, del inglés Hilbert Transform) elimina las altas frecuencias de la señal dejando únicamente la silueta o contorno de baja frecuencia a la que denominamos envolvente. Como ya se dijo en el apartado 2.2.2., el análisis de la envolvente de la señal nos permite un mejor análisis de la señal sobre todo en condiciones con ruido frente a otras técnicas como la FT.

La HT es una transformación lineal que se obtiene al realizar la convolución de la señal $x(t)$ con $1/(\pi \cdot t)$ como podemos observar en la ecuación 2.4.

$$x(t) = \frac{1}{\pi} \cdot \int_{-\infty}^{\infty} x(u) \cdot \frac{1}{t-u} \cdot du \quad (2.4)$$

Tiene las siguientes propiedades [4]:

1. La parte real coincide con la magnitud de la señal de entrada
2. La parte imaginaria está en cuadratura con la señal de entrada. Esto significa que cada componente del espectro de la parte imaginaria está a 90º respecto de la misma componente de la parte real.

Al estar en cuadratura las partes real e imaginaria, al obtener el módulo se eliminan las componentes de alta frecuencia y sólo nos queda la envolvente de la señal.

2.2.3. La Transformada Wavelet

Como ya adelantábamos 2.2.1, la transformada de Fourier es una herramienta que nos sirve únicamente cuando las señales a tratar eran estacionarias. Por ello, se empezaron a buscar alternativas como la STFT para el tratamiento de señales no estacionarias y posteriormente, a raíz de ésta última, surge la Transformada Wavelet (WT, del inglés Wavelet Transform) donde al igual que la STFT se realiza el análisis en el dominio de tiempo-frecuencia. La principal diferencia radica en el análisis multiresolución con ventanas dilatadas que permite hacer un buen análisis tanto en frecuencias altas como en bajas sin perder información.

Para ponernos en antecedentes, vamos a ver desde un punto de vista histórico la primera referencia que encontramos sobre las wavelet que podemos situar a principios de siglo XX, en un período de tiempo entre los estudios de Fourier acerca de la transmisión de calor donde daba a conocer la FT y la aparición de la STFT, por lo que en realidad, la gestación de las wavelet es anterior a la STFT aunque su desarrollo definitivo se dio a partir de la aparición de la STFT.

Como punto de partida nos encontramos con la tesis doctoral escrita por Alfred Haar [6] donde sus investigaciones le condujeron al desarrollo de un conjunto de funciones de base rectangular. Unos años después, este conjunto de funciones fueron englobadas en una familia de wavelets, la denominada wavelet de Haar, siendo éstas la familia de wavelets más simple hasta el momento por ser funciones que consisten en un pequeño pulso positivo, seguido de un pequeño pulso negativo y por ello no diferenciables. Posteriormente, Paul Levy descubrió que las funciones de Haar eran más adecuadas que las funciones de Fourier en su caso de estudio, lo que influyó el estudio de este tipo de funciones que resultó en el origen de las denominadas wavelet que atribuimos a Jean Morlet, que ayudado por Grossman, desarrollaron la técnica del escalado y desplazamiento de las funciones de la ventana de análisis y cuya forma de onda resultante denominaron wavelet. La ecuación que propusieron para el muestreo de la señal a analizar es la siguiente (2.5):

$$S(\tau, a) = \int_{-\infty}^{\infty} s(t) \cdot \frac{1}{\sqrt{a}} \cdot \Psi^* \cdot \left(\frac{t-\tau}{a} \right) \cdot dt \quad (2.5)$$

Donde Ψ^* es el conjugado de la wavelet madre que será la que se escala y se desplaza para determinar los niveles de comparación con la señal $s(t)$. El valor de a es el factor de escala y τ es el factor de traslación en el tiempo.

Las wavelet $S(\tau, a)$ que son generadas de una misma wavelet madre Ψ tienen diferentes valores de los parámetros de escala y traslación pero conservan la misma forma. El factor de escala sirve para cubrir todos los rangos de frecuencia de manera que valores grandes de a corresponden a frecuencias bajas y valores pequeños a altas frecuencias.

Tanto la FT como la Transformada Wavelet, comparten una similitud que reside en que en ambos se realiza una comparación, en el caso de la FT lo que se realiza es una correlación de la señal con una función sinusoidal y en el caso de la Transformada Wavelet lo que se realiza es una correlación entre la señal y una función que se denomina wavelet madre.

La elección de la wavelet madre dependerá de la aplicación para la cual se esté utilizando la técnica de la WT. Hay muchas familias de Wavelet madre [7], pero podemos destacar la Morlet, Daubechies, Symlet o Meyer entre las más utilizadas. Algunos ejemplos de las Familias Wavelet son representadas en la figura 2.4.

A continuación se tratan las diferentes técnicas basadas en la WT como son la Transformada Wavelet Continua (CWT, del inglés *Continuous Wavelet Transform*), la Transformada Wavelet Discreta (DWT, del inglés *Discrete Wavelet Transform*), el análisis multiresolución (MRA, del inglés *Multiresolution Analysis*) y la Transformada en Paquetes Wavelet (WPT, del inglés *Wavelet Packets Transform*).

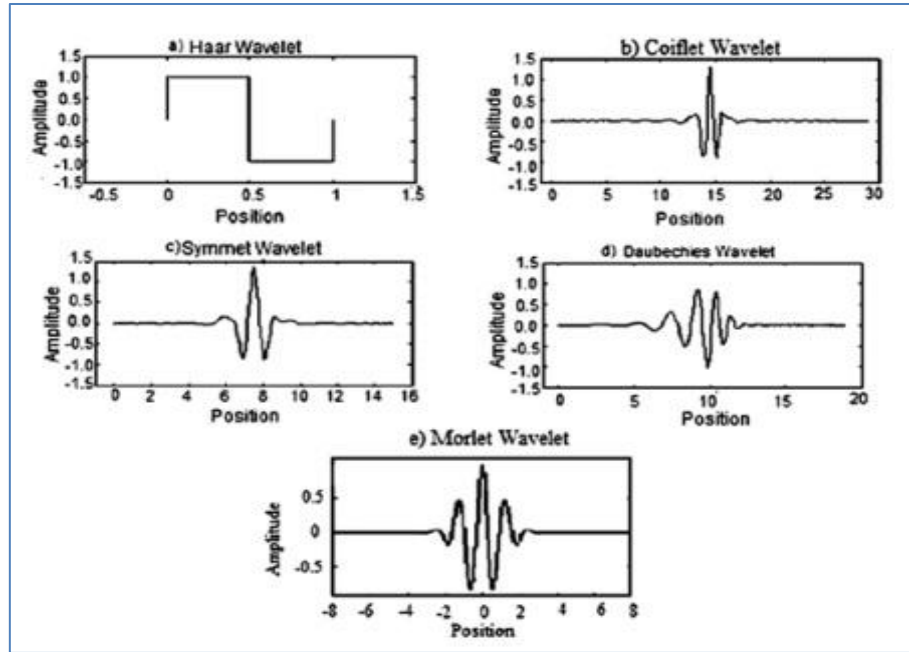


Figura 2.4: Se representan algunas de las Familias de Wavelet más utilizadas como Wavelet madre: (a) Wavelet Haar (b) Wavelet Coiflet (c) Wavelet Symlet (d) Wavelet Daubechies (e) Wavelet Morlet

2.2.3.1. Transformada Wavelet Continua

Es el tipo de transformada que se ha introducido en el apartado 2.2.3. Es una técnica muy parecida a la STFT en cuanto a que se realiza de manera muy similar. Se multiplica una función, en este caso una función wavelet, de igual manera que en la STFT se multiplicaba la señal por una función ventana y la transformada se calcula para distintos segmentos de la señal en el dominio del tiempo. Un ejemplo [5] de esto se muestra en la figura 2.5.




Figura 2.5. Ejemplo de transformada para distintos segmentos de la señal en el dominio del tiempo

La característica más significativa de la CWT y que sirve para eliminar los problemas de resolución de la STFT, es que el ancho de ventana varía a medida que se evalúa la transformada para cada componente del espectro. En las figuras 2.6a y 2.6b se puede observar un ejemplo de representación de la señal temporal y su CWT.




Figura 2.6a: Representación de señal temporal.




Figura 2.6b: Representación de la CWT de la señal temporal.

2.2.3.2. Transformada Wavelet Discreta

La DWT se basa en aplicar la WT a señales discretas mejorando la eficacia computacional mediante la discretización de los parámetros de escala y tiempo (a, τ) que calculábamos en la CWT, sin pérdida de calidad en la información obtenida. La función que gobierna esta transformada se muestra en la ecuación (2.6):

$$\Psi_{j,k}(n) = a^{-\frac{j}{2}} \cdot \Psi(a^{-j} \cdot n - k \cdot \tau) \quad (2.6)$$

Habitualmente, los parámetros de escala y tiempo los definimos según la escala diádica como se muestra en la ecuación (2.7):

$$a = 2^j \quad \tau = k \cdot 2^j \quad \text{para } a > 0 \text{ y } b > 1 \quad (2.7)$$

De esta manera, la DWT de una función discreta $f(n)$ viene dada por la ecuación (2.8):

$$DWT_n(j, k) = a^{-\frac{1}{2}} \cdot \int f(n) \cdot \Psi(a^{-j} \cdot n - k \cdot \tau) dn \quad (2.8)$$

Para la reconstrucción de la señal inicial $f(n)$ a partir de los coeficientes obtenidos mediante la ecuación 2.8, se debe cumplir la condición que aparece en la ecuación 2.9:

$$A \|f(n)\|^2 \leq \frac{2}{A+B} \cdot \sum_j \sum_k |DWT_n|^2 \leq B \|f(n)\|^2 \quad (2.9)$$

Cumpliendo con la condición de la ecuación anterior nos encontramos con que la transformada inversa se define como se muestra en la ecuación 2.10:

$$f(n) \approx \frac{2}{A+B} \cdot \sum_j \sum_k DWT_n \cdot \Psi_{j,k}(n) \quad (2.10)$$

En cuanto a los valores de A y B, cuanto más se acerquen entre sí, más precisa será la reconstrucción. En el caso de que $A=B=1$, la transformada es ortogonal.

2.2.3.3. Análisis Multirresolución

A modo de resumen de todo lo anterior, la CWT se puede evaluar de forma discreta para su uso en computadoras pero con una gran desventaja, que consiste en la gran redundancia de información y por ello tiempos de cálculo muy elevados. Por ello se utiliza la DWT mediante la cual conseguimos la información suficiente como para que la reconstrucción de la señal sea correcta siendo mucho más fácil de implementar que la CWT. Al igual que ocurrió con la DFT donde surgieron algoritmos que permitían una aplicación de la misma más eficaz que englobamos en la FFT, en el caso de la DWT estos algoritmos surgen teniendo como base el análisis multiresolución.

El análisis multiresolución tiene como base la codificación de sub-bandas propuesto por Crochiere, Weber y Flanagan. Pocos años después, Burt culminaría en una técnica que denominó codificación piramidal, la cual conocemos con el nombre de análisis multiresolución.

Fue a partir del trabajo de S. Mallat [8] cuando se da un nuevo punto de inflexión en la evolución de las Wavelet al encontrar relaciones entre Filtros Espejo en Cuadratura (QMF, del inglés *Quadrature Mirror Filters*), algoritmos piramidales y bases ortonormales de funciones Wavelet. A partir de este trabajo, Daubechies [9] desarrolló un grupo de funciones de base ortonormal, diferenciables y de soporte compacto que las hacen muy útiles para su uso en el ámbito de la ingeniería.

El objetivo del MRA no es distinto al que perseguimos mediante la CWT puesto que lo que buscamos es la representación en tiempo-escala de una señal discreta, con la diferencia del uso de diferentes filtros con distintas frecuencias de corte para el análisis de la señal en diferentes escalas. El MRA procesa una señal discreta a través de un filtro digital paso alto y media banda con respuesta impulso eliminando todas las frecuencias que estén por debajo de la mitad de la mayor frecuencia de la señal y de un filtro paso bajo y media banda con respuesta impulso eliminando todas las frecuencias que están por encima de la mitad de la mayor frecuencia de la señal.

En señales discretas, la frecuencia se expresa en radianes dando el valor de 2π radianes a la frecuencia de muestreo. Tras pasar el filtro a la señal, nos la encontramos descompuesta en una señal de detalle (altas frecuencias) y una señal de aproximación (bajas frecuencias), cuyo número de muestras resultante es el mismo que el inicial pero con una banda de frecuencias de la mitad respecto al inicial en cada una de las partes.

Ahora, de acuerdo a la regla de Nyquist, podemos eliminar la mitad de las muestras, tomando una de cada dos muestras consecutivas sin pérdida de información relevante, por tener la señal una frecuencia superior a $\pi/2$ radianes en vez de π . Con esto, formamos el primer nivel de descomposición que podemos expresar matemáticamente mediante la ecuación (2.11) y (2.12).

$$D(k) = \sum_n X(n) \cdot g(2k - n) \quad (2.11)$$

$$A(k) = \sum_n X(n) \cdot h(2k - n) \quad (2.12)$$

Donde $D(k)$ es la parte de la señal que pasa por el filtro paso alto y que por lo tanto son los coeficientes de detalle y $A(k)$ es la parte de la señal que pasa por el filtro paso bajo, siendo los coeficientes de aproximación. El término k hace referencia al nivel de descomposición. Para esclarecer a qué nos referimos con los niveles de descomposición queda reflejado en la figura 2.7 cómo queda descompuesta la señal tras pasar por los filtros.

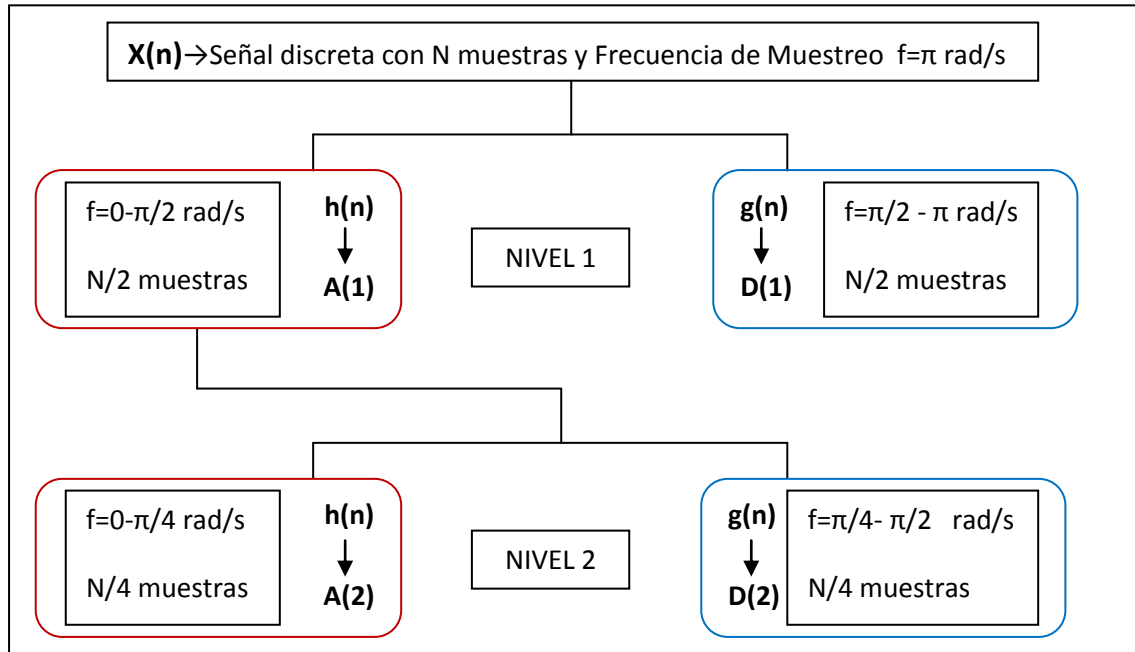


Figura 2.7. Esquema del MRA que genera la Descomposición Wavelet hasta nivel 2

Para conseguir niveles de descomposición mayores a los que se muestran en la figura 2.7, únicamente se necesita aplicar un nuevo filtro paso bajo al nivel de aproximación por lo que en cada nivel los coeficientes de detalle son los definitivos, mientras que los de aproximación podemos seguir descomponiéndolos. Todo este proceso podemos invertirlo de manera que podamos obtener la señal original $X(n)$ a partir de los coeficientes de aproximación y detalle mediante la expresión representada en la ecuación (2.13).

$$X(n) = \sum_{k=1}^{\infty} D(k) \cdot g(2k - n) + A(k) \cdot h(2k - n) \quad (2.13)$$

En la ecuación 2.13, se suman cada uno de los coeficientes de detalle que se obtienen en cada nivel de descomposición multiplicados por la función del filtro correspondiente ($g(n)$) y los coeficientes de aproximación del último nivel multiplicados por su correspondiente función del filtro ($h(n)$).

2.2.3.4. Transformada de Paquetes Wavelet

En el MRA podemos ver como los niveles que denominábamos de detalle no éramos capaces de descomponerlos, suponiendo esto una pérdida de información importante en las frecuencias altas. Por este motivo aparece la transformada de paquetes Wavelet (WPT, del inglés *Wavelet Packet Transform*) para capacitarnos a descomponer toda la información hasta el nivel seleccionado. El procedimiento que se utiliza es el mismo que en el MRA salvo porque descomponemos también en cada nivel la información de detalle. Esta secuencia queda representada en la figura 2.8.

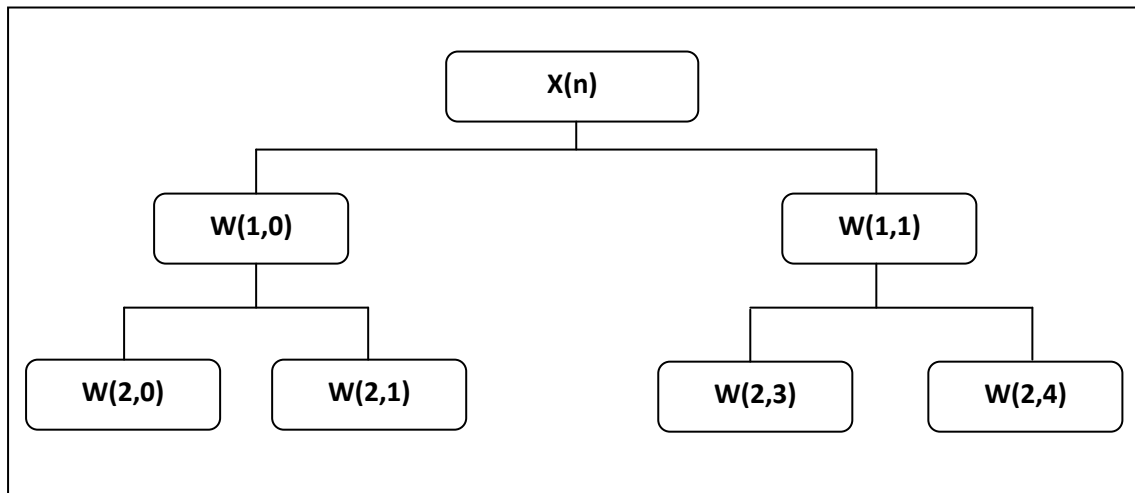


Figura 2.8: Representación del esquema de descomposición en paquetes Wavelet de una señal discreta

Siendo el término $W(k,j)$ el que representa los coeficientes de un paquete, k el nivel de descomposición y j la posición del paquete dentro del nivel de descomposición.

Podemos utilizar estos coeficientes WPT para someter la señal a numerosos estudios puesto que nos arrojan información característica sobre la señal y que nos puede ser de mucha utilidad. Algunas de las características importantes de la WPT son los

contenidos de frecuencia en cada uno de los paquetes y la energía que contienen, que se desarrollan a continuación.

2.2.3.4.1. Contenido de frecuencia en la WPT

Cada vez que descomponemos la señal en un nivel más, estamos dividiendo entre dos la banda de frecuencia de cada uno de los paquetes y por lo tanto determinamos la resolución en frecuencia de cada paquete. La banda de frecuencia de cada paquete viene dada por la ecuación 2.14:

$$f_r = \frac{\pi}{2^k} \quad (2.14)$$

Intuitivamente podríamos pensar que al descomponer cada uno de los paquetes en los diferentes niveles, podríamos ser capaces de identificar el rango de frecuencias que comprende cada paquete ordenándolos tal y como lo hacíamos en la figura 8, pero al realizar la descomposición nos encontraríamos con que esto no sucede así. Es fundamental entender cómo se realiza la descomposición en los diferentes niveles y en la información de aproximación y de detalle de cada nivel y sobretodo cómo la procesamos para ser capaces de ordenar los paquetes de manera que obtengamos un orden natural de frecuencias.

Para explicar el origen de esta descolocación de las bandas de frecuencia debemos trasladarnos al proceso de descomposición de la señal mediante los filtros paso bajo y paso alto para obtener una información de aproximación y otra de detalle. En el caso en que nos encontramos que es el de la WPT, tanto la información de detalle como la de aproximación se han de descomponer en una nueva información de detalle y aproximación de cada uno de ellos.

En el caso de la información de detalle, por razones computacionales, es necesario aplicarle una simetría especular y una traslación al origen de coordenadas por lo que cada vez que descomponemos una información de detalle, los dos paquetes que generamos aparecen desordenados respecto al orden natural de frecuencia. De esta manera los paquetes en cada nuevo nivel se van desordenando progresivamente.

2.2.3.4.2. Energía de la WPT

La energía de una señal puede ser un rasgo característico y por tanto, objeto de ser utilizado para diversos estudios relacionados con el análisis de señales. Éste concepto de energía está directamente ligado a las propiedades que conocemos de la transformada

de Fourier. El Teorema de Parseval define que la potencia de las señales es equivalente a la suma de la potencia de sus componentes espectrales. Por tanto, al realizar la WPT obteniendo los distintos paquetes con sus diferentes bandas de frecuencia, podemos calcular la energía de cada uno siendo ésta una parte de la energía total de la señal.

La energía de un paquete podemos obtenerla mediante la ecuación 2.15.

$$E(k, j) = \sum_i [w_i(k, j)]^2 \quad (2.15)$$

Donde k es el nivel de descomposición y j la posición del paquete dentro del nivel de descomposición.

Puesto que los valores de energía que obtenemos de cada paquetes son una parte del total, la práctica habitual es calcular la energía total de la señal mediante la suma de las energías de todos los paquetes para poder normalizar los valores de energía de cada paquete y poder visualizar mucho mejor que parte de la energía de la señal corresponde a cada paquete. La ecuación mediante la que obtenemos la energía total es la 2.16 y la ecuación mediante la que obtenemos los valores normalizados es la 2.17.

$$E_T = \sum_j E(k, j) \quad (2.16)$$

$$E(k, j_{rel}) = \frac{E(k, j)}{E_T} \quad (2.17)$$

En la figura 2.9, podemos ver un ejemplo de la obtención de la energía WPT de una señal vibratoria de un rodamiento con defecto en bola y un nivel de descomposición 4.

En el presente PFC utilizaremos para el análisis de vibraciones tanto la FFT y la HT para la obtención de la envolvente de la señal, que nos proporcionarán una visión en el dominio de la frecuencia, como la WPT, dominio tiempo-frecuencia, cuyo análisis es algo más complejo puesto que se analizará qué nivel de descomposición necesitaremos y se obtendrán las energías relativas de cada paquete para la posterior clasificación mediante sistemas inteligentes.




Figura 2.9. En el eje horizontal se muestra el número de paquete y en el eje vertical el porcentaje de energía de cada paquete ($E(k, j)$) respecto al total ($E(k, j_{rel})$).

2.3. Sistemas de clasificación inteligentes

2.3.1. Introducción a los sistemas de clasificación inteligentes

Los sistemas de clasificación inteligentes surgen por la necesidad de trabajar con numerosos sistemas de clasificación individuales que nos resultaría extremadamente complejo y costoso trabajar con cada uno por separado además de no obtener un resultado óptimo por no tener en cuenta la relación entre ellos. Esto quedará reflejado en el capítulo 4 del presente PFC donde se utilizará un sistema de clasificación inteligente para el diagnóstico del estado de un rodamiento mediante la comparación de la energía de sus paquetes una vez realizada la WPT.

Cada uno de estos paquetes por separado podrían suponer un sistema de clasificación al variar su nivel de energía en función del estado del rodamiento, pero para obtener resultados óptimos necesitamos establecer una relación entre los parámetros o valores de cada uno de los paquetes que nos determinen el estado conjunto de todos ellos, aportando más información al sistema y por lo tanto permitiendo una mejor clasificación/diagnosis.

A estos sistemas de clasificación inteligentes se les conoce coloquialmente (o más bien comercialmente) como inteligencia artificial (AI, del inglés *Artificial Intelligence*), estableciendo que son inteligencias no naturales en especímenes no vivos. El sobrenombre de AI viene de la capacidad que se les aporta a las máquinas de pensar, evaluar y actuar ante diversos problemas para alcanzar un objetivo siempre basándose en la optimización

de los mismos. Dentro de este ámbito, podemos encontrar numerosos tipos de conocimiento y de sistemas de representación los cuales dependen por ejemplo de la adquisición de los datos o de los tipos de datos.

Podemos dividir en cuatro categorías [10] la AI en función de cómo actúan:

- **Sistemas que piensan como humanos:** tratan de imitar la lógica humana. Serían aplicables a aquellas actividades relacionadas con la toma de decisiones o la resolución de problemas. Un ejemplo son las redes neuronales artificiales.
- **Sistemas que actúan como humanos:** imitan el comportamiento humano a la hora de actuar. Se engloban todo lo relacionado con la robótica en este tipo de sistemas.
- **Sistemas que piensan racionalmente:** su finalidad es imitar el pensamiento lógico racional humano. Los sistemas expertos son los que se ajustan a estas características y permiten imitar la actividad de un humano para resolver un problema sobre un área específica. Los sistemas expertos constan de una base de conocimientos o información proporcionada por uno o varios expertos en ése área específico. Con este tipo de sistemas se busca una mejor calidad y rapidez de las respuestas para conseguir una mejora de productividad.
- **Sistemas que actúan racionalmente:** al igual que los sistemas que actúan como humanos, imitan el comportamiento humano pero en este caso de forma racional. Un ejemplo son los agentes inteligentes que mediante sensores, son capaces de percibir el entorno, procesar la información y reaccionar o actuar consecuentemente.

El campo de uso de este tipo de sistemas es muy diverso pero en los que más trascendencia ha tenido en los últimos años son en el diagnóstico médico, exploración minera o petrolera, diagnóstico de fallos en sistemas eléctricos y centrales nucleares, diseño en ingeniería, planificación y transporte, economía y robótica.

Algunas de las características ideales para un sistema de computación son [11]:

- Procesamiento rápido de grandes cantidades de datos de forma masiva y paralela.
- Aprendizaje y “evolución” para adaptarse mejor a los objetivos.
- Manejo robusto de datos con grandes cantidades de ruido.
- Alto grado de autonomía.

2.3.2. Inteligencia artificial computacional

La AI clásica podríamos dividirla en dos ramas bien diferenciadas: la inteligencia artificial convencional o simbólico-deductiva, basada en el análisis estadístico del comportamiento humano y cuyos sistemas no requieren de aprendizaje para la resolución de problemas nuevos porque únicamente se dedican a la resolución de problemas anteriores, y la inteligencia artificial computacional o subsimbólica-inductiva que es la

rama a la que pertenecen las máquinas de soporte vectorial que utilizaremos en el presente PFC.

La inteligencia artificial computacional, o simplemente inteligencia computacional como la nombran la mayoría de los autores, aparece debido a que hay muchos problemas que requieren algoritmos cuyo esfuerzo computacional sería inabordable con la tecnología actual para obtener una solución óptima en un tiempo razonable.

La AI clásica se basa en algoritmos muy cerrados que únicamente son capaces de resolver casos ya expuestos anteriormente pero es capaz de resolverlos muy eficientemente. La CI (del inglés, *Computational Intelligence*) se encarga de estudio de problemas para los que no hay algoritmos efectivos, es una metodología que muestra capacidad para aprender y afrontar nuevas situaciones mediante la generalización, descubrimiento, asociación y abstracción. A pesar de que esto último ya supone un gran cambio en la metodología respecto a la AI clásica, lo que verdaderamente caracteriza la CI es que hay una colaboración efectiva entre el ser humano y el ordenador en contraposición a lo que ocurre con la AI que se centra en llevar el conocimiento experto al ordenador.

2.3.2.1. Aprendizaje

En la inteligencia artificial, la idea principal es trasladar el raciocinio o comportamiento humano a la máquina y el aprendizaje es uno de los pilares en este proceso. Se busca el desarrollo de técnicas que permitan a la máquina lo que nosotros denominamos aprender, pero que en el caso de una máquina quizás el concepto que mejor se adapta es establecer límites.

La forma de establecer límites se basa en el análisis de datos y extracción de patrones que nos lleva al campo de la estadística, siendo capaces de generalizar comportamientos y de poder variar los límites a través de la experiencia. El objetivo final de este “aprendizaje” es el de mejorar la realización de una tarea a través de la experiencia, recogiendo datos y llevando esos límites de los que hablábamos anteriormente a valores capaces de solucionar de forma óptima la tarea.

Los diferentes algoritmos de aprendizaje los podemos agrupar en función de su salida[10]:

- **Aprendizaje supervisado:** mediante los datos que le aportamos, cada uno con su correspondiente etiqueta para definir su clase, se crean modelos que corresponden a la etapa de aprendizaje. Por ello hay una correspondencia entre los datos de entrada y salida del sistema. Su principal uso serán los problemas de clasificación.
- **Aprendizaje no supervisado:** la principal diferencia entre el modelo supervisado y éste radica en que los datos que se le introducen no están etiquetados y el propio sistema debe encargarse de ello.

- **Aprendizaje por refuerzo:** su método de aprendizaje no se basa en análisis de regresión o estadística sino que usa el método de ensayo-error por el cual, a cada acción suya recoge la respuesta de sus acciones del medio sirviendo ésta de elemento de entrada.
- **Transducción:** es un método derivado del aprendizaje supervisado pero a diferencia de éste, su función no es construir una función que determine una solución a problemas de este tipo sino simplemente trata de predecir la clase de salida en función de los elementos de entrada.
- **Aprendizaje multitarea:** emplea conocimientos adquiridos anteriormente para la resolución de problemas similares.

De todos los algoritmos de aprendizaje, nos centraremos únicamente en los de aprendizaje supervisado por ser los que comprenden las máquinas de soporte vectorial que son la que utilizaremos en el presente PFC.

2.3.2.2. Sistemas de aprendizaje supervisado.

Este tipo de sistemas se caracteriza por permitirnos deducir una función a partir de los datos de entrenamiento. Este proceso de entrenamiento es controlado por un agente externo que es quien determina si la respuesta que obtenemos es la que se debería generar a partir de la inicial. Tras entrenarla con varios ejemplos, la función debería ser capaz de predecir la salida correctamente.

Algunos de los sistemas de aprendizaje supervisado más importantes son:

- Redes neuronales
- Máquinas de soporte vectorial
- Clasificador Bayesiano
- Modelos de los k-vecinos más próximos
- Árboles de decisión
- Funciones de base radial

En cualquiera de estos tipos de sistemas de aprendizaje supervisado, los pasos a seguir para la resolución de un problema son los mismos y los resumimos a continuación:

1. Selección de los ejemplos de entrenamiento. Tipos de datos a utilizar.
2. Obtención de los datos a utilizar para el entrenamiento.
3. Determinar el formato de los datos de entrada. A partir de los datos de entrenamiento, extraer las características que nos sirvan para el desarrollo de la función.
4. Determinar la función que resuelve el problema. Es en este punto donde seleccionamos la técnica que queremos utilizar: redes neuronales, árboles de decisión, máquinas de soporte vectorial, etc.
5. Ajuste de los parámetros del algoritmo y validación del modelo.

Como ya adelantábamos en apartados anteriores, en el presente PFC únicamente se va a utilizar máquinas de soporte vectorial para la clasificación. Éste método es capaz de dar solución a problemas de identificación, optimización, clasificación, control de procesos y reconocimiento de patrones para los cuales sería necesario una cantidad de recursos enorme y cuyo propósito es el de solucionarlos de manera exacta.

2.3.3. Máquinas de soporte vectorial

La teoría de las máquinas de soporte vectorial (SVM, del inglés *Support Vector Machine*) fue desarrollada por Vapnik basándose en la idea de minimización de riesgo estructural. Se parte de un conjunto de datos etiquetados, que utilizamos para entrenar una SVM, teniendo como objetivo construir un modelo que será capaz de predecir la clase de unos nuevos datos que le introduzcamos.

Actualmente, el uso de la SVM está muy extendido y se emplea en campos como el reconocimiento de textos o escritura [18], recuperación de información, identificación de voz, identificación de matrículas [17], etc.

Para que las SVM puedan cumplir con su objetivo, que no es otro que clasificar correctamente un conjunto de muestras, lo primero que se debe de hacer es realizar una primera etapa de aprendizaje. Para ello, se mapean los puntos de entrada a un espacio de características de una dimensión mayor. Esta operación hace que sea más fácil encontrar el hiperplano que los separe y maximice el margen entre las diferentes clases de datos. Podemos ver gráficamente este proceso en la figura 2.10.




Figura 2.10. Uso de un espacio de características de una dimensión mayor para encontrar el hiperplano que maximice la separación entre clases.

Esta teoría llevada al lenguaje matemático, nos lleva a buscar el hiperplano que denominamos $h(x) = 0$ que sea capaz de maximizar la separación de un conjunto de datos

$X \in \mathcal{R}^d$ según la clase $Y \in \{-1, 1\}$ a la que pertenecen. El hiperplano $h(x)$ estará a la misma distancia de los ejemplos más cercanos entre ellos de cada categoría.

Puesto que el hiperplano $h(x)$ debe estar a la misma distancia de ambas clases, nos encontramos ante un problema de optimización para el cual se utilizan técnicas de programación cuadrática. Podemos ver esto representado en la figura 2.11. Los datos que utilizamos para obtener el hiperplano se les conoce como vectores de entrenamiento.

A partir de los datos de entrada, la SVM deberá ser capaz de proporcionarnos su clase según la regla de clasificación $f(x_i) = \text{signo}(h(x_i))$.

Habitualmente, de la muestra de datos total que se dispone se separa, aproximadamente, el 25% para poder validar el modelo tras el entrenamiento. Por ello, tras la fase de aprendizaje usamos ese conjunto de datos al que denominamos conjunto de test con el que comprobamos la fiabilidad del hiperplano separador que hemos obtenido.




Figura 2.11. Representación gráfica de la obtención del hiperplano separador de clases.

Esta fase de calibración es de vital importancia para el posterior uso del modelo, proporciona información acerca de si el número de muestras que estamos utilizando para el entrenamiento es suficiente y de si las clases son fácilmente separables. El objetivo en este aspecto será conseguir clasificaciones correctas con el menor número de datos de entrenamiento, de manera que consigamos que los costes computacionales sean lo menores posibles.

Máquinas de soporte vectorial para clasificación binaria

En las clasificaciones binarias únicamente existirán dos clases. Como ya establecimos en el apartado anterior un intervalo para la clase Y, utilizaremos esta notación para considerar una de las dos clases como positiva con $y=1$ mientras que la otra clase será la negativa y cuyo valor asociado será $y=-1$.

Una vez que hemos etiquetado correctamente los datos, nos podemos encontrar con que estos datos sean linealmente separables, que sería el caso óptimo por poder establecer márgenes máximos, o que por el contrario nos encontremos con que su separación sea no lineal o que exista cierto nivel de ruido, por lo que necesitaremos establecer unos márgenes que se denominan blandos.

Máquinas de soporte vectorial lineal con margen máximo.

Este tipo de SVM sólo es posible utilizarlas cuando los datos son linealmente separables o lo que es lo mismo, sólo podemos usarlas cuando el hiperplano $h(x)$, cuya ecuación se muestra en 2.19, sea el separador óptimo siendo una línea recta.

$$h(x) = w^T x + b = 0 \quad (2.19)$$

Donde w y $x \in \mathbb{R}^d$, siendo d la dimensión del espacio de entrada.

Para la solución de este tipo de casos donde tenemos un conjunto de datos de entrada que organizamos en vectores, de manera que el vector de entrada contenga tanto la posición como su clase $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$, se cumplirá que en función del lado del que estén los datos respecto al hiperplano separador:

$$w^T x_i + b > 0, \quad \text{para } y_i = 1, i = 1, \dots, n \quad (2.20)$$

$$w^T x_i + b < 0, \quad \text{para } y_i = -1, i = 1, \dots, n \quad (2.21)$$

De las ecuaciones anteriores, se puede obtener una única ecuación debido a que el signo de la ecuación viene marcado por la clase del dato (etiqueta y_i) por lo que queda representado en la ecuación 2.22 esta expresión.

$$y_i(w^T x_i + b) > 0, \quad \text{para } i = 1, \dots, n \quad (2.22)$$

Ahora que ya tenemos la ecuación que define el hiperplano separador, tendremos que centrarnos en aquellos vectores cuya distancia a un vector de la otra clase, es la menor entre todos los de su clase, puesto que serán estos los que tengan más influencia para la determinación de la posición del hiperplano separador. A este conjunto de vectores los denominamos vectores soporte y para que podamos resolver el problema de optimización deben cumplir las condiciones de las ecuaciones 2.23 y 2.24.

$$h(x_i) = 1, \quad \text{para } y_i = 1 \quad (2.23)$$

$$h(x_i) = -1, \quad \text{para } y_i = -1 \quad (2.24)$$

Como hemos definido al hiperplano separador como aquel que maximiza la distancia entre clases, no podrá haber ningún dato de entrenamiento dentro de los márgenes, por lo que tendremos que modificar la ecuación 2.22 de manera que introduzca esta nueva restricción. Esta modificación queda reflejada en la ecuación 2.25.

$$y_i(w^T x_i + b) \geq 1, \quad \text{para } i = 1, \dots, n \quad (2.25)$$

Teniendo en cuenta que la distancia de un punto cualquiera al hiperplano separador viene dada por la ecuación 2.26 y que los puntos más próximos (vectores soporte) cumplen que $|h(x_i)| = 1$, siendo su distancia al hiperplano la definida por la ecuación 2.27, para encontrar los valores de ω y b habrá que resolver el problema de optimización consistente en maximizar el margen entre clases, o lo que es lo mismo maximizar la distancia entre un vector soporte y el hiperplano.

$$\text{dist}(h, x) = \frac{|h(x)|}{\|\omega\|} \quad (2.26)$$

$$\text{dist}(h, x) = \frac{1}{\|\omega\|} \quad (2.27)$$

Este planteamiento de resolución del problema queda reflejado gráficamente en la figura 2.12.




Figura 2.12. Representación de SVM lineal de margen máximo

Se puede demostrar que al maximizar $\frac{1}{\|\omega\|}$ se obtiene la misma solución que al minimizar $\frac{\|\omega\|}{2}$.

El problema se puede exponer en su forma dual que es más sencilla de resolver. Como es un problema de programación no lineal se emplean multiplicadores de Langrange y las condiciones de Karush-Kuhn-Tucker.

El planteamiento del problema es el siguiente:

$$L(\omega, b, \alpha) = \frac{1}{2} \|\omega\|^2 + \sum_{i=1}^n \alpha_i (1 - y_i (\omega^T x_i + b)) \quad (2.28)$$

$$\frac{\partial L(\omega, b, \alpha)}{\partial \omega} = 0; \quad \omega = \sum_{i=1}^n y_i \alpha_i x_i \quad (2.29)$$

$$\frac{\partial L(\omega, b, \alpha)}{\partial b} = 0; \quad \sum_{i=1}^n y_i \alpha_i = 0 \quad (2.30)$$

$$\alpha_i (1 - y_i (\omega^T x_i + b)) = 0 \quad 1 \leq i \leq n \quad (2.31)$$

$$1 - y_i (\omega^T x_i + b) \leq 0 \quad 1 \leq i \leq n \quad (2.32)$$

$$\alpha_i \geq 0 \quad 1 \leq i \leq n \quad (2.33)$$

Según las condiciones de Karush-Kuhn-Tucker, en el caso en que los datos no son vectores soporte, $\alpha_i = 0$.

Sustituyendo en la ecuación de Lagrange, se obtiene la función objetivo de la formulación dual:

$$L(\omega, b, \alpha) = \sum_{i=1}^n \alpha_i + \frac{1}{2} \sum_{i=1}^n y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (2.34)$$

De esta nueva función objetivo debemos obtener los valores de ω y b que definen nuestro hiperplano. Esto se consigue al maximizar:

$$\sum_{i=1}^n \alpha_i + \frac{1}{2} \sum_{i=1}^n y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (2.35)$$

Sujeto a las condiciones:

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad \alpha_i \geq 0 \quad 1 \leq i \leq n \quad (2.36)$$

Teniendo en cuenta que los datos que no sean vectores soporte tendrán un valor de $\alpha_i = 0$.

Al resolver se obtiene la siguiente ecuación:

$$\omega = \sum_{i=1}^n y_i \alpha_i x_i \quad (2.37)$$

$$h(x) = w^T x + b = \sum_{i=1}^n y_i \alpha_i x_i^T x + b \quad (2.38)$$

$$b = -\frac{1}{2} \left(\max_{y_i=-1} \{\omega^T x_j\} + \min_{y_i=1} \{\omega^T x_j\} \right) \quad (2.39)$$

Se puede observar que la ecuación del hiperplano solo depende de los vectores soporte ya los puntos restantes cumplen $\alpha = 0$. Esto significa que se llegaría a la misma solución si se volviera a calcular la frontera de decisión únicamente con los vectores soporte.

Máquinas de soporte vectorial no lineal.

Cuando los datos de entrada no son separables linealmente, tendremos que buscar alguna solución que permita separarlos. Ésta pasa por transformar los datos a un espacio de características de mayor dimensión en el que los datos si puedan ser separados linealmente por un hiperplano.

Hemos de tener en cuenta, que a pesar de que en dicho espacio de características sí podemos separar linealmente los datos, al volver a pasar los datos a su espacio de entrada dicho hiperplano de separación no será lineal, sino que será una función que en función de cómo se distribuyan los datos puede ser polinómica, gaussinana... Este efecto podemos verlo gráficamente en la figura 2.13.




Figura 2.13. Representación de los datos de entrada al pasarlos al espacio de características.

Las funciones que se utilizan para la transformación de los datos de entrada a un espacio de dimensión mayor se denominan funciones núcleo o kernel. Representan el producto vectorial en el espacio de características.

Las ecuaciones que resuelven el problema de optimización son las mismas que usábamos para la resolución de problemas con datos linealmente separables (ecuaciones

2.37, 2.38 y 2.39) pero sustituimos el producto vectorial del espacio de entrada $x_i^T x$ por el del espacio de características que se corresponde con el del kernel:

$$h(x) = \sum_{i=1}^n y_i \alpha_i K(x_i, x) + b \quad (2.40)$$

Las funciones núcleo o kernel más utilizadas son:

- **Función polinómica:** asociada a un polinomio con coeficientes a_i . La expresión de la función se muestra en la ecuación 2.41.

$$P(x) = \sum_{i=0}^n a_i x^i = a_0 + a_1 x^1 + a_2 x^2 + \dots + a_n x^n \quad (2.41)$$

La función núcleo o kernel quedaría:

$$K(x, x') = (x^T \cdot x' + c)^d \quad (2.42)$$

- **Función gaussiana:** se define por la siguiente expresión:

$$f(x) = a \cdot \exp\left(\frac{-(x - b)^2}{2c^2}\right) \quad (2.43)$$

Donde a, b y c son constantes reales y $a > 0$.

La función núcleo o kernel quedaría:

$$K(x, x') = \exp\left(\frac{-\|x - x'\|^2}{2\sigma^2}\right) \quad \text{con } \sigma > 0 \quad (2.44)$$

- **Función sigmoide:** a las funciones sigmoidales se les da este nombre por su forma característica. Su gráfica tiene la forma de la letra S, de manera que tiene tres partes bien diferenciadas, una primera de crecimiento lento, una intermedia de crecimiento muy rápido y por último una tercera de decrecimiento lento o

eventualmente de crecimiento muy lento. Describen muchos de los procesos que ocurren en la naturaleza además de curvas de aprendizaje.

El grupo de funciones sigmoidales incluye tangentes parabólicas, arcotangentes, etc.

La función núcleo o kernel quedaría:

$$K(x, x') = \tanh(s(x^T \cdot x') + r) \quad (2.45)$$

En función del tipo de kernel que elijamos y de sus parámetros característicos, se pueden conseguir diferentes fronteras de decisión (ver figura 2.14). Por ello nuestra misión será conseguir la función que mejor se adapte a nuestros datos y variar los parámetros de manera que consigamos la mejor frontera de decisión posible.

A priori no es fácil conocer cuál será el kernel que mejor se adapte a nuestros datos de entrada por lo que la única opción que nos queda es probar con estos datos y diferentes kernel analizando el error en cada caso y quedarnos con el que mejores resultados arroje.




Figura 2.14. Representación de las fronteras de decisión en función de la función núcleo seleccionada [32].

Generalmente la función gaussiana es la que mejor se adapta a los datos y es la que se recomienda usar [21] para obtener buenos resultados. En el capítulo 4, se proponen sistemas de clasificación donde se utiliza la función Gaussiana (RBF, del inglés *Radial Basis Function*) como función núcleo tratando de modificar su parámetro Gamma

para optimizar el entrenamiento y obtener mejores resultados en la clasificación. El efecto que produce modificar el parámetro Gamma de la función RBF lo podemos ver en la figura 2.15.

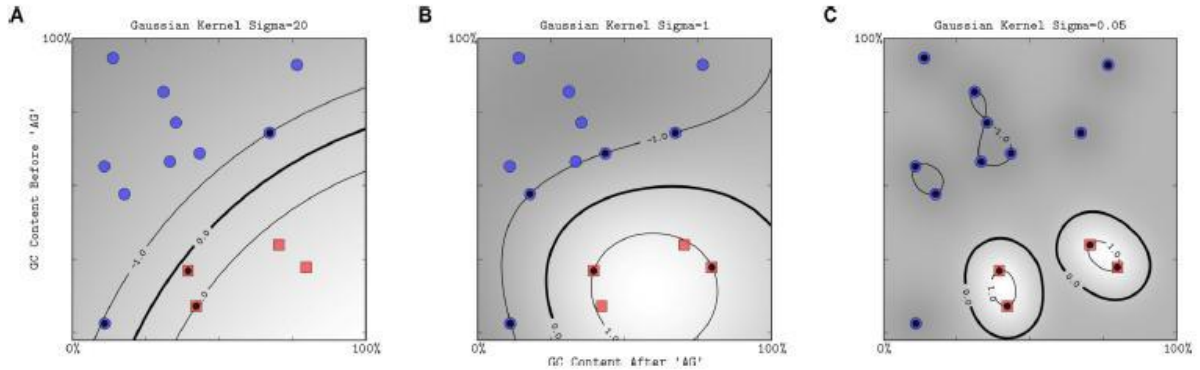


Figura 2.15. Representación del hiperplano separador utilizando una función núcleo RBF, modificando el valor del parámetro Gamma.

Máquinas de soporte vectorial lineal con margen blando.

Como ya adelantábamos anteriormente, nos vamos a encontrar datos de entrada en los que puede existir ruido, lo que puede llevarnos a tener datos atípicos o datos etiquetados incorrectamente que nos condicionen mucho la obtención del hiperplano separador al poder ejercer de vector soporte. Podemos ver gráficamente un ejemplo de esto en la figura 2.16.




Figura 2.16. Ejemplo de dato mal etiquetado que condiciona la obtención del hiperplano separador.

Es esta razón por la cual necesitamos mecanismos que nos eviten errores debido a este tipo de circunstancias. Para ello se introducen unas variables de holgura ξ en el problema de optimización.

Puesto que es un problema en el cual los datos son linealmente separables partimos de las consideraciones que ya hicimos anteriormente pero añadiendo esta nueva variable de holgura trataremos de minimizar la expresión 2.46:

$$\frac{1}{2} \omega^T \omega + C \sum_{i=1}^n \xi_i \quad (2.46)$$

Imponiendo las condiciones:

$$y_i(w^T x_i + b) \geq 1 - \xi_i \quad 1 \leq i \leq n \quad (2.47)$$

$$\xi_i \geq 0 \quad 1 \leq i \leq n \quad (2.48)$$

Estas condiciones representan que ahora podemos encontrar datos dentro del margen, pero que simplemente serán ignorados para la obtención del hiperplano separador de manera que no distorsione los cálculos.

Resolviendo la ecuación 2.46 sujeta a las restricciones 2.47 y 2.48 llegamos a la siguiente formulación en la que se deberá maximizar la ecuación 2.49.

$$\sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^n y_i y_j \alpha_i \alpha_j K(x_i, x_j) \quad (2.49)$$

Imponiendo las condiciones:

$$\sum_{i=1}^n \alpha_i y_i = 0 \quad 0 \leq \alpha_i \leq C \quad 1 \leq i \leq n \quad (2.50)$$

La diferencia con la SVM de margen máximo es que α no puede ser mayor que C . El parámetro C es el que controla el número de errores de clasificación que permitimos en la etapa de entrenamiento por lo que calibrar el valor de C es esencial para una correcta clasificación. En el presente PFC se utilizará un margen blando para conseguir un modelo correcto y se buscará el valor de C que nos permita una mejor clasificación posterior.

Máquinas de soporte vectorial para clasificación multiclase.

Las máquinas de soporte vectorial están diseñadas para clasificaciones binarias pero no debería ser un gran problema para su uso en problemas donde tengamos más de dos clases de datos. Podemos utilizar las SVM para problemas multiclase convirtiendo este problema en un problema binario o en varios problemas en función de lo que necesitemos. Este método de conversión de un problema multiclase en un problema binario puede resumirse en dos tipos de clasificaciones:

- Clasificación 1-v-r (del inglés *one versus rest*): en cada uno de los problemas consideramos la clase que buscamos la clase positiva y el resto será la clase negativa.
- Clasificación 1-v-1 (del inglés *one versus one*): se hacen comparaciones de las clases de dos en dos de manera que al final comparemos todas con todas. Es una división del problema en tantos subproblemas como existan.

Ambos tipos de clasificación serán utilizados en el desarrollo experimental del presente PFC y se tratará de buscar el método que mejor funcione con el tipo de datos que se va a utilizar.

3. Desarrollo del proyecto. Adquisición y análisis de señales.

En el presente capítulo se detallan: la adquisición de los datos, englobando el procedimiento para la toma de datos y las características del banco de pruebas, y el tratamiento de las señales, mediante técnicas basadas en el dominio de la frecuencia y técnicas basadas en el dominio tiempo-frecuencia, siempre teniendo en cuenta que este tratamiento de los datos va encaminado a su posterior uso con sistemas de clasificación inteligentes en el capítulo 4.

3.1. Adquisición

Para la realización del presente PFC, se han obtenido las señales de un banco de ensayo, utilizando una base de datos proporcionada por la Case Western Reserve University [22] y de la cual detallaremos a continuación todos los datos que nos proporcionan. A pesar de no haber realizado los ensayos, detallaremos el procedimiento que habitualmente se sigue para este tipo de ensayos de acuerdo a [12,13].

3.1.1. Procedimiento para la toma de datos en banco de ensayo

El procedimiento de ensayo sigue una cadena de medida que parte de la máquina, donde se hace la simulación del funcionamiento del rodamiento en condiciones de trabajo, un acelerómetro recoge los datos y éstos son procesados por un acondicionador de la señal (filtro+amplificador). Una vez que tenemos los datos acondicionados para poder procesarlos, son recogidos por una tarjeta de adquisición la cual mediante un software adecuado estará conectada a un ordenador, permitiendo traspasar todos los datos recogidos. Podemos ver un esquema gráfico de la cadena de medida en la figura 3.1.




Figura 3.1. Esquema gráfico de la cadena de medida.(a) banco de ensayo,(b) Acelerómetro,(c) Acondicionador de señal,(d) Tarjeta de adquisición de datos, (e)Ordenador.

3.1.2. Banco de ensayos y componentes




Figura 3.2. Fotografía del banco de ensayos proporcionada por la Case Western Reserve University [22].

El banco de pruebas consiste en un motor (parte izquierda), un convertidor de par/encoder (centro), un dinamómetro (parte derecha) y un control electrónico, el cual no aparece en la imagen.

Los rodamientos del ensayo soportan el eje del motor. Un único punto de fallo es introducido a los rodamientos usando una máquina de electroerosión (EDM) con unos diámetros de fallo de 7 milésimas de pulgada, 14 milésimas de pulgada, 21 milésimas de pulgada y 28 milésimas de pulgada.

Para los diámetros de fallo de 7, 14 y 21 milésimas de pulgadas se utilizaron rodamientos de la casa SKF y para los de 28 milésimas de pulgada utilizaron rodamientos NTN equivalentes a los anteriores.

Las especificaciones del rodamiento del extremo del motor, incluyendo sus dimensiones y frecuencias de defectos, están reflejadas en la tabla 3.1.

Rodamiento del extremo del motor: 6205-2RS JEM SKF, Rodamiento de bolas. Dimensiones en milímetros.				
Diámetro interior	Diámetro exterior	Espesor	Diámetro de las bolas	Diámetro de la pista
25,0012	51,9988	15,0012	7,9400	39,0398
Frecuencias de defecto(múltiplos de la velocidad de giro en Hz).				
Pista interna	Pista externa	Defecto en jaula	Defecto en bola	
5,4152	3,5848	0,39828	4,7135	

Tabla 3.1. Dimensiones y frecuencia de defecto del rodamiento 6205-2RS JEM SKF.

Las frecuencias de defecto se dan en función de la velocidad de giro puesto que el ensayo se realiza a 4 velocidades de giro diferentes (tabla 3.2) y como veremos en el apartado 3.2, estas frecuencias teóricas dependen de la velocidad de giro.

Carga del motor (HP)	Velocidad del motor aproximada (rpm)
0	1797
1	1772
2	1750
3	1730

Tabla 3.2. Cargas del motor y su velocidad de giro medidas en rpm.

Los datos de vibraciones se obtienen mediante acelerómetros, los cuales están unidos a la carcasa mediante bases magnéticas. Los acelerómetros están situados en la posición de las 12 en punto en ambos extremos de la carcasa del motor. Durante el experimento, un acelerómetro está unido al soporte de la base del motor (bancada).

Las señales de vibración se recogen mediante un recolector de 16 canales y se postprocesan en MATLAB®. Todos los archivos de datos están en formato Matlab (*.mat). Los datos digitales son recogidos a 12000 muestras por segundo y a 48000 muestras por segundo para el rodamiento del extremo del motor. Los datos de velocidad y potencia se obtienen usando un convertidor de par/encoder y se toman a mano.

3.2. Análisis de las señales

Para el análisis de las señales, debemos tener en cuenta el tipo de datos que tenemos y qué información queremos obtener de ellos. En este caso, no necesitamos hacer ningún tipo de análisis en el dominio del tiempo puesto que únicamente tenemos los datos de uno de los ejes coordenados (normalmente, el acelerómetro que se utiliza en este tipo de ensayos es triaxial, proporcionándonos información en los tres ejes) y por lo tanto la tarea de seleccionar los datos del eje coordenado que nos proporcione una mejor información ya está hecha. Los siguientes pasos a realizar serán: primero, un análisis en el dominio de la frecuencia para la detección de las frecuencias de fallo y determinar si el uso de la transformada rápida de Fourier es adecuado para su posterior clasificación por sistemas inteligentes y segundo, se introducirá el análisis de paquetes wavelet y se seleccionará el nivel de descomposición adecuado para la posterior clasificación.




Figura 3.3. Esquema de los pasos a realizar

3.2.1. Introducción a las frecuencias características de fallo de los rodamientos.

Antes de avanzar en el análisis de las señales, se va a realizar un pequeño análisis de cuáles son las razones por las que se producen los fallos en los rodamientos y cómo influyen éstos en su análisis en frecuencia.

Los rodamientos son un tipo de cojinetes capaces de soportar y transmitir los esfuerzos que genera el eje sobre el que estén montados a otro elemento estructural de la máquina, siendo elementos con elevados riesgos de fallo debido a las altas cargas y a los ciclos de cargas que soportan.

Como ya se mencionó en el capítulo 1, los rodamientos se utilizan como fusibles mecánicos, por ser elementos baratos en comparación con el resto de elementos de una máquina y habitualmente fáciles de sustituir. Los rodamientos tienen una vida útil limitada, medida en horas de funcionamiento, que depende principalmente de las vueltas realizadas por el rodamiento y la magnitud de la carga que soporta, proporcionando una estimación de cuándo se debe sustituir un rodamiento antes de que se produzca un fallo. Puesto que las condiciones de funcionamiento no serán ideales (variaciones en la magnitud de la carga, cargas discontinuas...), el material con el tiempo se fatigará, provocando grietas en la capa justo debajo de la superficie, que gradualmente se extenderán hasta la superficie provocando el defecto incluso antes de lo previsto por el fabricante.

Esta medida de la vida de un rodamiento forma parte del mantenimiento preventivo, donde los rodamientos son sustituidos antes de que acabe la vida útil prevista por el fabricante, evitando un fallo del rodamiento en funcionamiento que provocaría vibraciones perjudiciales para la máquina o en el peor de los casos la necesidad de parar por un mal funcionamiento.

En el presente proyecto, se va a analizar la posibilidad de realizar un mantenimiento predictivo de los rodamientos mediante el análisis de las señales vibratorias obtenidas de un rodamiento en funcionamiento, con diferente gravedad de defecto, de manera que podamos discernir entre un rodamiento sano o uno con algún tipo de defecto además de ser capaces de reconocer el tipo de defecto que tiene.

Los tipos de defecto que pueden aparecer en un rodamiento están asociados a cada uno de los elementos que forman el rodamiento y que pueden fallar. Los elementos que forman la gran mayoría de los rodamientos son: Aro interior, Aro exterior, Jaula y Elementos rodantes. Podemos ver su disposición en la figura 3.4.

Cuando tenemos un rodamiento con fallo en alguno de sus elementos en movimiento, en cada vuelta, se produce un impacto de los elementos rodantes sobre el elemento defectuoso que excita unas frecuencias periódicas llamadas frecuencias fundamentales de fallo. Diferentes estudios demuestran que en función del tipo de defecto que encontramos en los rodamientos se producen diferentes frecuencias características de fallo y las cuales dependen de las dimensiones del rodamiento y de la velocidad de giro del mismo [1]:




Figura 3.4. Elementos de un rodamiento de bola.

- Frecuencia de paso del elemento rodante por un defecto en la pista interna (Hz):

$$BPFI (Hz) = \frac{nb}{2} \cdot f_r \cdot \left(1 + \frac{D_b}{D_p} \cdot \cos(\alpha) \right) \quad (3.1)$$

- Frecuencia de paso del elemento rodante por un defecto en la pista externa (Hz):

$$BPFO (Hz) = \frac{nb}{2} \cdot f_r \cdot \left(1 - \frac{D_b}{D_p} \cdot \cos(\alpha) \right) \quad (3.2)$$

- Frecuencia de rotación de la jaula que contiene los elementos rodantes (Hz):

$$CFF (Hz) = \frac{D_p}{2 \cdot D_b} \cdot f_r \cdot \left(1 - \left(\frac{D_b}{D_p} \cdot \cos(\alpha) \right)^2 \right) \quad (3.3)$$

- Frecuencia de paso de algún defecto de la bola (Hz):

$$BSF (Hz) = \frac{f_r}{2} \cdot \left(1 - \frac{D_b}{D_p} \cdot \cos(\alpha) \right) \quad (3.4)$$

Donde:

f_r → Frecuencia de rotación relativa entre la pista interna y la externa en Hz.

nb → Número de elementos rodantes.

D_b → Diámetro de las bolas.

D_p → Diámetro medio.

α → Ángulo de contacto [°].

En nuestro caso de estudio, las frecuencias teóricas nos las daban ya calculadas para el rodamiento del que se recogieron los datos en función de la velocidad de rotación del mismo expresada en Hz (tabla 3.3).

En la siguiente tabla se reflejan las frecuencias teóricas de defecto en pista interna, externa, en jaula y en bola para el rodamiento 6205-2RS JEM SKF:

Frecuencia de defecto	Velocidad de giro			
	1797 rpm	1772rpm	1750 rpm	1730 rpm
Pista Interna	162,18 Hz	159,91 Hz	157,69 Hz	156,12 Hz
Pista Externa	107,36 Hz	105,86 Hz	104,39 Hz	103,35 Hz
Jaula	11,93 Hz	11,76 Hz	11,59 Hz	11,48 Hz
Bola	141,17 Hz	139,19 Hz	137,26 Hz	135,89 Hz

Tabla 3.3. Frecuencia característica de fallo en función del tipo de defecto y velocidad de giro

Para el análisis en frecuencia de las señales, vamos a utilizar dos métodos: la Transformada Fourier y el análisis de la envolvente de la señal mediante la transformada de Hilbert.

3.2.2. Análisis en frecuencia de señales. Búsqueda de la frecuencia característica de fallo.

Análisis de las señales mediante la transformada de Fourier.

Como vimos en el capítulo 2, la Transformada de Fourier nos permite pasar una señal del dominio del tiempo al dominio de la frecuencia. Mediante la aplicación de la transformada rápida de Fourier a la señal, deberíamos ser capaces de observar los picos de amplitud en las frecuencias características de fallo. Esto dependerá en gran medida, del ruido de la señal y de la gravedad del defecto.

A continuación se mostrarán los gráficos donde se representan las señales aplicándoles la transformada rápida de Fourier para rodamientos con niveles de defecto

de 0,007", 0,014", 0,021" y 0,028" con defecto en bola, defecto en pista interior y defecto en pista exterior y tres velocidades distintas de ensayo.

- **Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.**

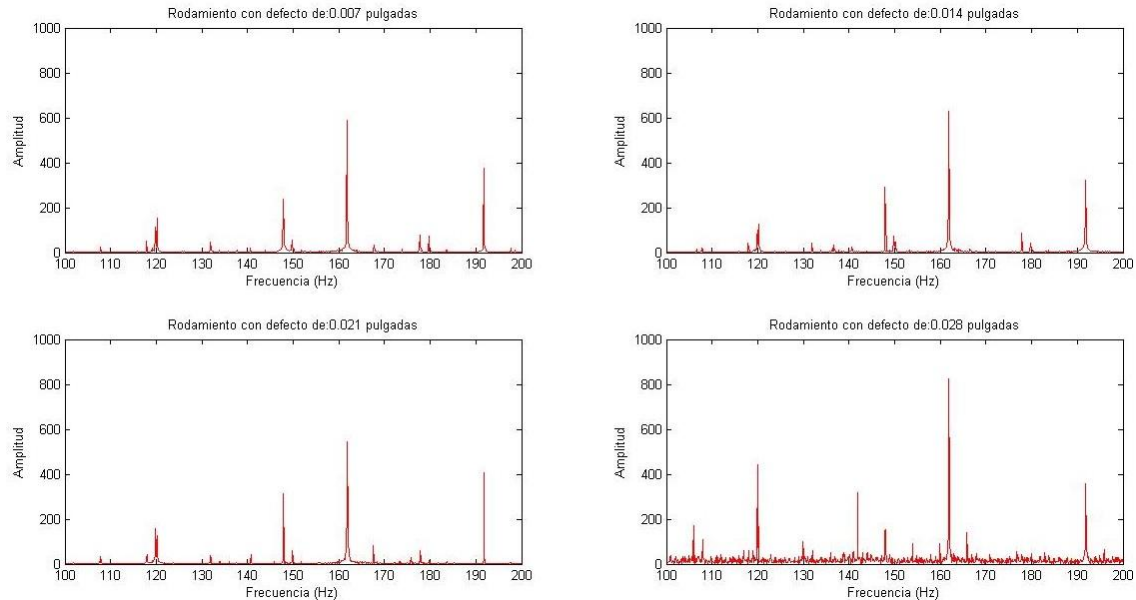


Figura 3.5. FFT de señales de rodamientos de bolas con defecto en bola, frecuencia característica de fallo 141,17 Hz

Como era de esperar, a medida que el defecto es mayor, es más fácil de identificar en el espectro de frecuencia un pico de amplitud en la frecuencia característica de fallo. Esto sólo viene a confirmarnos que existe un defecto y que los datos teóricos coinciden con la representación realizada, pero sólo para defectos grandes.

En el caso de los dos primeros tamaños de defectos seríamos incapaces de poder establecer si se trata de un rodamiento con defecto y mucho menos de predecir o conocer su tamaño de defecto. Como las cuatro velocidades de ensayo son muy próximas entre sí, realizaremos el análisis comparativo únicamente con la mayor y la menor para poder analizar si esta diferencia de velocidad de giro influye en la capacidad para detectar los defectos en el espectro de la señal. El resto de datos con distintas velocidades han sido analizados y sus resultados se muestran en el anexo 1.

Puesto que no tenemos datos de un rodamiento sano, como los datos para rodamiento con defecto en bola y tamaño de defecto más pequeño apenas muestran cambios significativos en la frecuencia de defecto, la utilizaremos como modelo respecto al cual compararemos otras señales de ser necesario.

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.

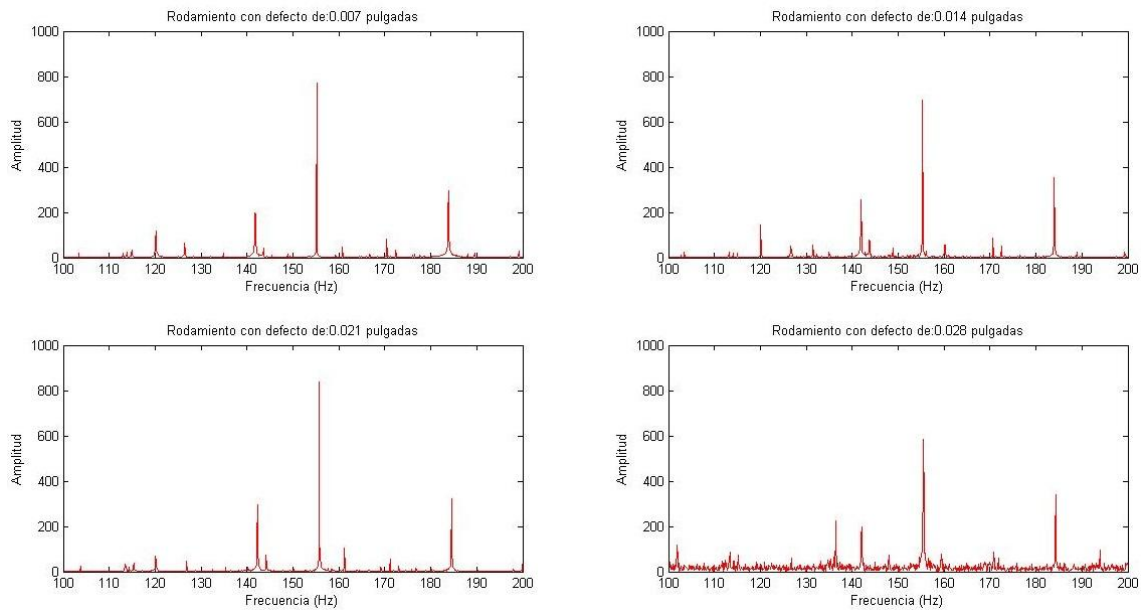


Figura 3.6. FFT de señales con defecto en bola, frecuencia característica de fallo 135,89 Hz

Al igual que ocurría en el análisis anterior, para tamaño de defecto pequeño es prácticamente inapreciable en el espectro de la señal el pico de amplitud en la frecuencia característica de fallo. Era de esperar este resultado puesto que no hay una gran diferencia de velocidades de giro entre ambos ensayos por lo que sus espectros son similares con una pequeña traslación de unos 6-8 Hz en los picos de amplitud.

Puesto que comprobamos que la velocidad de giro no supone un condicionante en estos análisis (por la pequeña diferencia de velocidades de giro), en los análisis para rodamientos con defecto en pista interna y pista externa sólo mostraremos los gráficos para una velocidad de giro que será á de 1797rpm (29,95 Hz).

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.

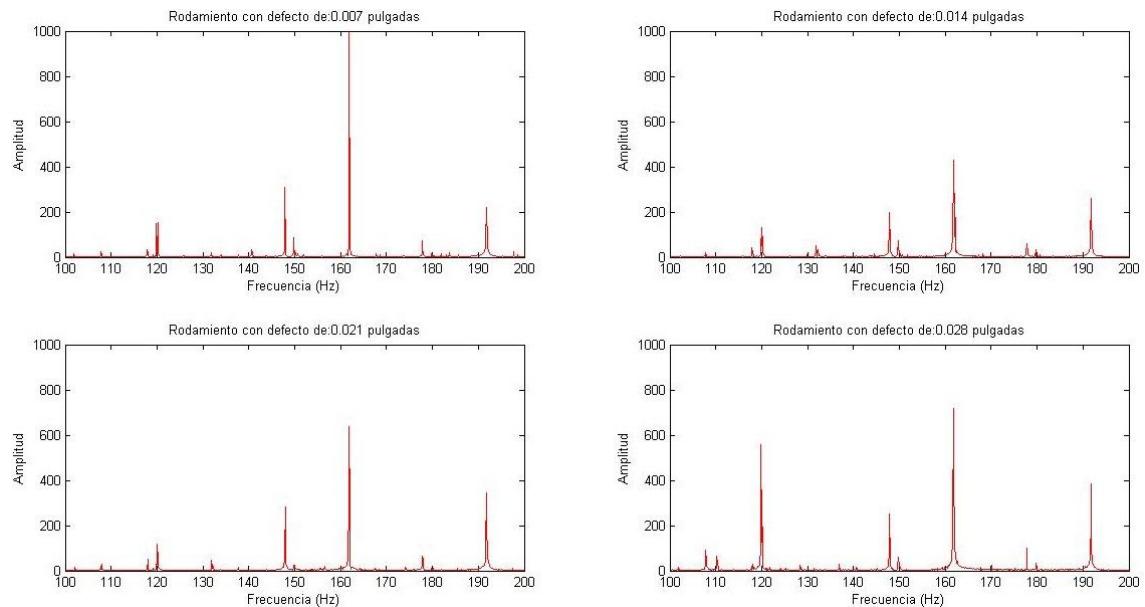


Figura 3.7. FFT de señales con defecto en pista interna, frecuencia característica de fallo 162,18 Hz

Como podemos observar, el pico de frecuencia que se da en 162,18 Hz, frecuencia característica de fallo para este tipo de defecto, es mucho mayor que en el caso de defecto en bola. Si nos fijamos en la representación de la señal de defecto en bola, podemos observar que dicho pico de frecuencia existe aun sin haber defecto en pista interna, por lo que lo más probable es que la frecuencia característica de fallo de pista interna coincida con alguna de las frecuencias de los elementos estructurales de la máquina y por ello quede enmascarado. No podemos establecer ningún tipo de criterio puesto que la amplitud no aumenta proporcionalmente al tamaño de defecto por lo que podemos asegurar que con este método no podríamos detectar el defecto en pista interna en esta máquina.

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.

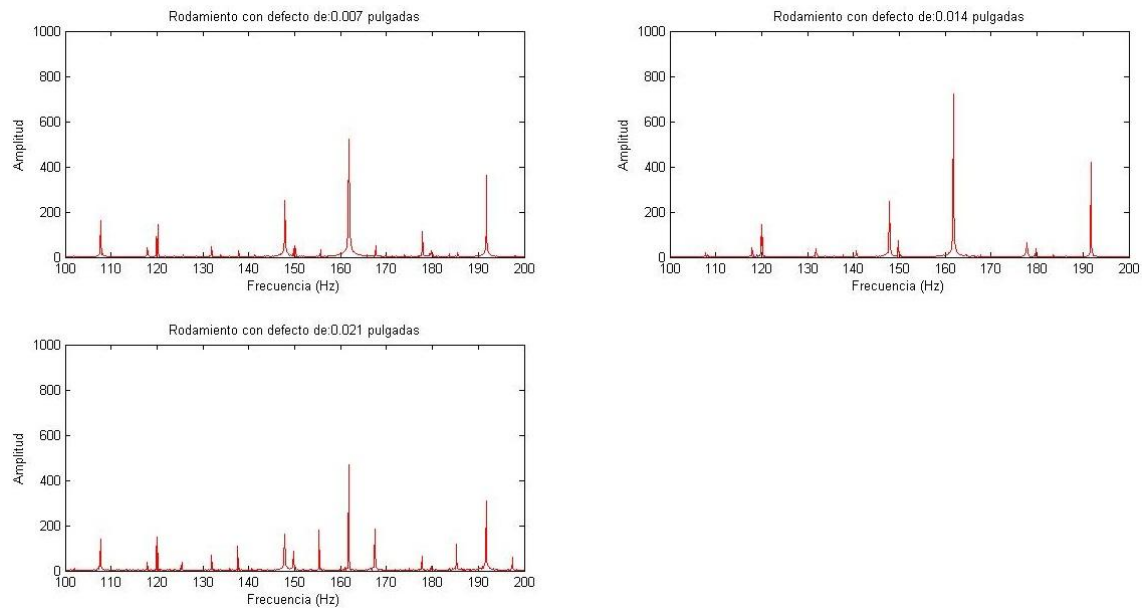


Figura 3.8. FFT de señales con defecto en pista externa, frecuencia característica de fallo 107,36 Hz

En el caso de defecto en pista externa, nos encontramos con algo parecido a lo que ocurría en el caso de pista interna puesto que la frecuencia característica de fallo coincide con alguna de las frecuencias de un componente del motor provocando que no podamos ver claramente una tendencia en la señal. En este caso el pico de amplitud para esa frecuencia no es tan pronunciado como en el caso de pista interna pero al comparar la señal con la que propusimos como modelo (rodamiento con defecto en bola de 0,007") podemos apreciar en la figura 3.5 que ese pico de frecuencia ya existía.




Figura 3.9. Rodamiento con defecto en bola con tamaño de defecto de 0,007"

Para concluir el análisis de los resultados que hemos obtenido mediante la transformada de Fourier, podemos afirmar que no es un buen método para la clasificación de señales con defectos puesto que no sigue una tendencia clara. Si tomamos como referencia la amplitud de la señal, no podemos establecer ningún tipo de sistema que nos permita conocer la gravedad del defecto porque no hay una relación proporcional entre la amplitud en la frecuencia característica de fallo y su tamaño de defecto en los casos de defecto en pista interna y externa. En el caso de defecto en bola el problema es que es muy difícil identificar la frecuencia característica de fallo porque en los tamaños de defecto pequeños no se aprecia ninguna variación de amplitud en la frecuencia característica de fallo teórica. Para descartar que estos resultados se debieran a ruido en la señal, vamos a hacer un análisis mediante la envolvente de la señal aplicando la transformada de Hilbert.

Análisis de las señales mediante la obtención de la envolvente de la señal

Utilizaremos el método de la envolvente de la señal mediante la transformada de Hilbert, debido a que los impactos de los elementos rodantes sobre el elemento con defecto, contienen baja energía y pueden verse atenuados/enmascarados por el ruido de mayor energía que producen otros elementos de la máquina. Mediante esta técnica se puede eliminar este ruido de mayor energía sin perder los impulsos producidos por el defecto en el rodamiento.

- **Comparación de señales de rodamiento con defecto en bola, para misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.**




Figura 3.10. Envolvente de la señal mediante la aplicación de la HT.

En esta representación, la línea roja corresponde a la envolvente de la señal y la línea azul a la transformada de Fourier. Se puede apreciar que prácticamente coinciden ambas representaciones, lo que nos hace pensar que los datos estén medidos en un entorno que minimiza al máximo el ruido y por lo tanto este método no es válido para tomar decisiones de clasificación puesto que tampoco lo era el método de Fourier. El resto de comparativas para distintos tipos de defecto se encuentran en el anexo 2.

3.2.3. Análisis en tiempo-frecuencia de señales. Uso de la Transformada de Paquetes Wavelet (WPT).

Para el análisis en tiempo-frecuencia utilizaremos la transformada de paquetes wavelet por ser una técnica utilizada en trabajos como [12,13,14,19,20] y que ha dado buenos resultados con otros sistemas de clasificación. Utilizaremos la energía de los paquetes Wavelet para su análisis como vector de características y su posterior clasificación.

El primer paso a realizar con este método es la selección del nivel de descomposición que utilizaremos. Para ello hemos de establecer las directrices que queremos seguir a la hora de decantarnos por un nivel u otro. En el presente proyecto se pretende utilizar niveles de descomposición que permitan que el coste computacional no sea muy elevado, puesto que la intención es la de la aplicación de esta técnica para sistemas de mantenimiento predictivo y por lo tanto en tiempo real, pero de manera que los resultados que obtengamos sean satisfactorios.

3.2.4. Selección del nivel de descomposición para el análisis de energía en los paquetes wavelet.

Para la selección del nivel de descomposición, hemos de tener en cuenta que vamos a dividir todo el rango de frecuencia de la señal en paquetes, los cuales contienen una banda de frecuencia concreta. Como ya mencionamos anteriormente, la diferencia de velocidades de giro entre los diferentes ensayos es muy pequeña y por ello, la diferencia entre los espectros de las señales es mínima (nos encontramos con una traslación de unos 6-8 Hz en los picos de frecuencia más significativos en el espectro), por lo que al seccionar el rango de frecuencia necesitaríamos seccionarlo en bandas muy estrechas para que esa pequeña diferencia de velocidades de giro nos produjera cambios significativos en la energía de los paquetes.

Se ha decidido hacer una descomposición desde el nivel 8 hasta el nivel 3 de manera que tendremos un máximo de 256 (2^8) paquetes en el caso del nivel de descomposición 8 y de 8 (2^3) paquetes en el caso de nivel de descomposición 3.

Buscaremos un nivel de descomposición en el cual, con un número de vectores lo menor posible, seamos capaces de clasificar correctamente las señales mediante sistemas de clasificación inteligentes.

En el presente capítulo se mostrarán únicamente las descomposiciones para niveles 8, 5 y 3. El resto de niveles de descomposición están representados en el anexo 3.

- **Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 8 de descomposición.**

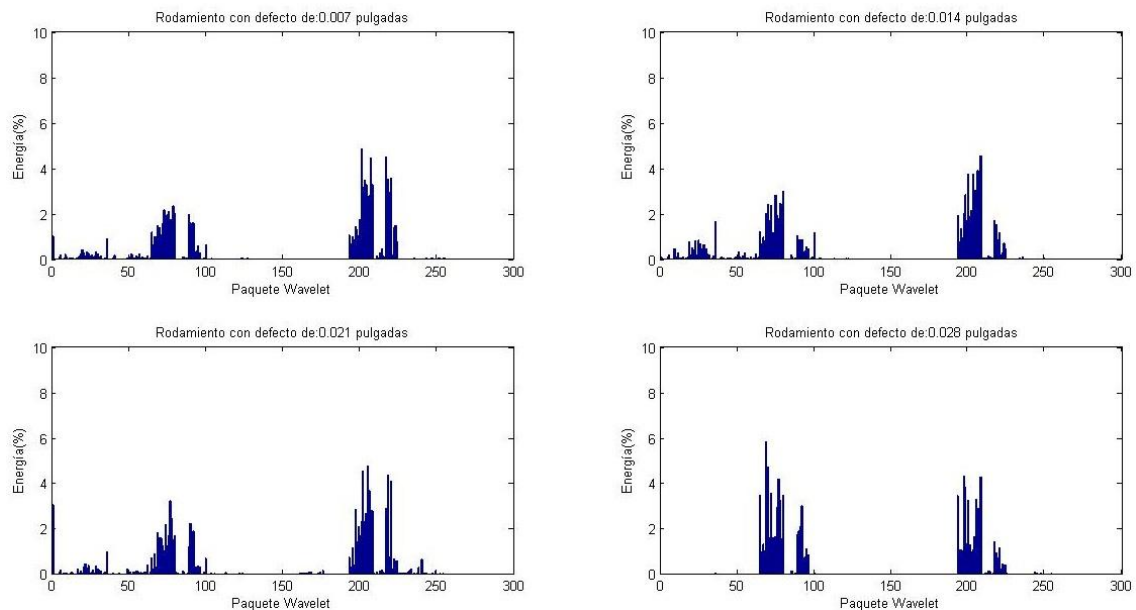


Figura 3.11. WPT con nivel de descomposición 8 para señal con defecto en bola

Como podemos ver en las representaciones anteriores, hay muchos paquetes que varían su nivel de energía por lo que la selección de un número pequeño de paquetes wavelet para la caracterización de su estado es compleja. Buscaremos con niveles de descomposición más pequeños en los que podamos ver más fácilmente el cambio de niveles de energía en paquetes wavelet concretos

- **Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 5 de descomposición.**

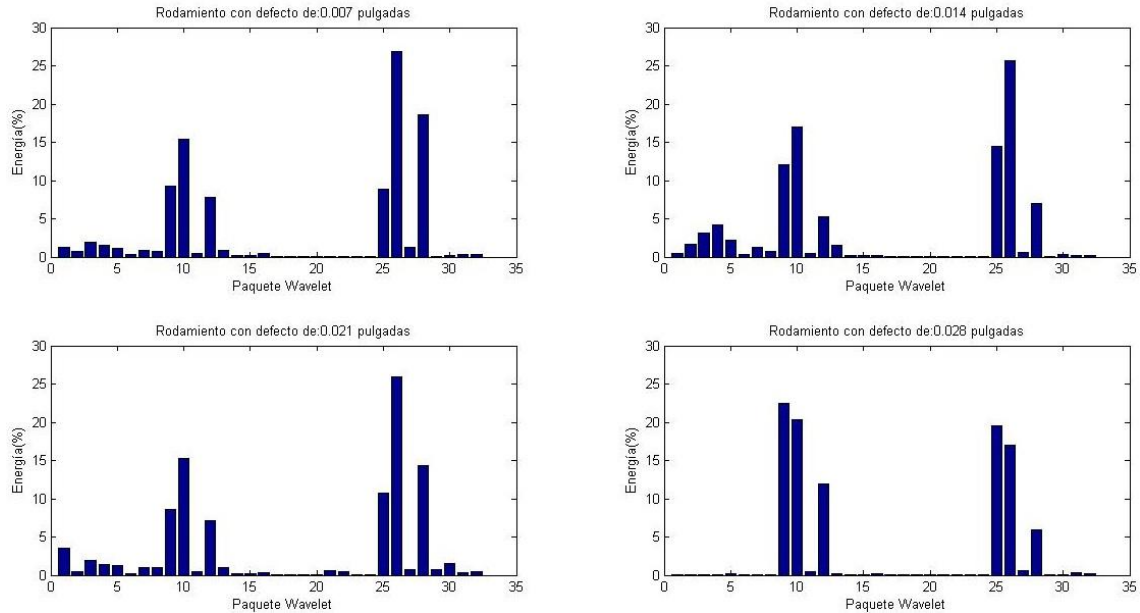


Figura 3.12. WPT con nivel de descomposición 5 para señal con defecto en bola

A pesar de que el número de paquetes que varían significativamente ha disminuido considerablemente, todavía con este nivel de descomposición necesitaríamos introducir un número elevado de paquetes wavelet en un sistema de clasificación inteligente para que fuese capaz de clasificarlo correctamente.

Lo que se puede ver más claro a medida que disminuimos el nivel de descomposición, es que hay dos zonas en las representaciones anteriores que nos indican que tenemos una variación más pronunciada de la energía de los paquetes wavelet y que por lo tanto serán esas dos zonas las que nos interese analizar. La primera zona comprende entre el paquete wavelet uno y el quince y la segunda zona entre el veinticinco y el veintiocho. Probaremos si con un nivel de descomposición 3 conseguimos ver de forma más clara este efecto.

- **Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 3 de descomposición.**

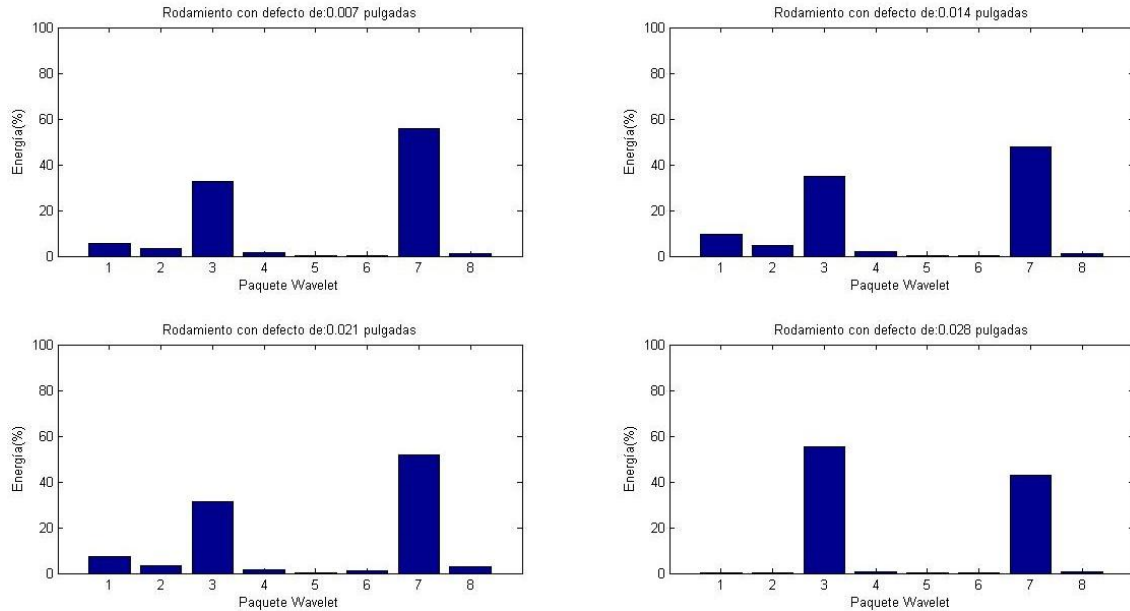


Figura 3.13. WPT con nivel de descomposición 3 para señal con defecto en bola

Con este nivel de descomposición podemos apreciar que cada uno de los estados puede quedar definido por sólo cinco de los ocho paquetes wavelet (1, 2, 3, 4 y 7), coincidiendo con la premisa que adelantábamos anteriormente.

Este nivel de descomposición cumple con las directrices que nos marcamos para la selección del nivel de descomposición. Utilizaremos solo cinco vectores minimizando el coste computacional y además, sabemos que esos 5 vectores contienen toda la información necesaria para su posterior clasificación.

4. Sistemas de clasificación y resultados

Como ya adelantamos en el capítulo 2, utilizaremos las máquinas de soporte vectorial para la clasificación de señales. Como vector de entrada al sistema de clasificación, utilizaremos la transformada de paquetes wavelet para la obtención de la energía de dichos paquetes con un nivel de descomposición de 3 tal y como justificamos en el capítulo 3.

En el presente capítulo, se explica la metodología utilizada para la realización de las clasificaciones de las señales. Se detalla cómo se han planteado los numerosos ensayos realizados y las herramientas de MATLAB® que ha sido necesario utilizar.

4.1. Máquinas de soporte vectorial. Tipos de clasificación multiclase.

Los tipos de clasificación multiclase ya quedaron definidos en el capítulo 2, por lo que únicamente nos centraremos en los aspectos relacionados con los datos procesados en el presente proyecto. Utilizaremos máquinas de soporte vectorial no lineales con margen blando y se aplicarán los dos tipos de clasificación multiclase (1-vs-1 y 1-vs-r), por lo que a continuación, se detalla la implementación particularizada a los datos del proyecto.

4.1.1. Clasificación multiclase 1-vs-r.

En la clasificación “uno contra el resto” (1-vs-r), se etiqueta cada clase de manera que existan tantas clases como tipos de datos, enfrentándose los datos de test a un entrenamiento formado por todas las clases. Podemos ver en la figura 4.1 como queda cada una de las clases etiquetadas y en la figura 4.2 la lógica que sigue el algoritmo para aplicar este tipo de clasificación.




Figura 4.1. Representación de datos con tres clases y sus correspondientes hiperplanos separadores [31].

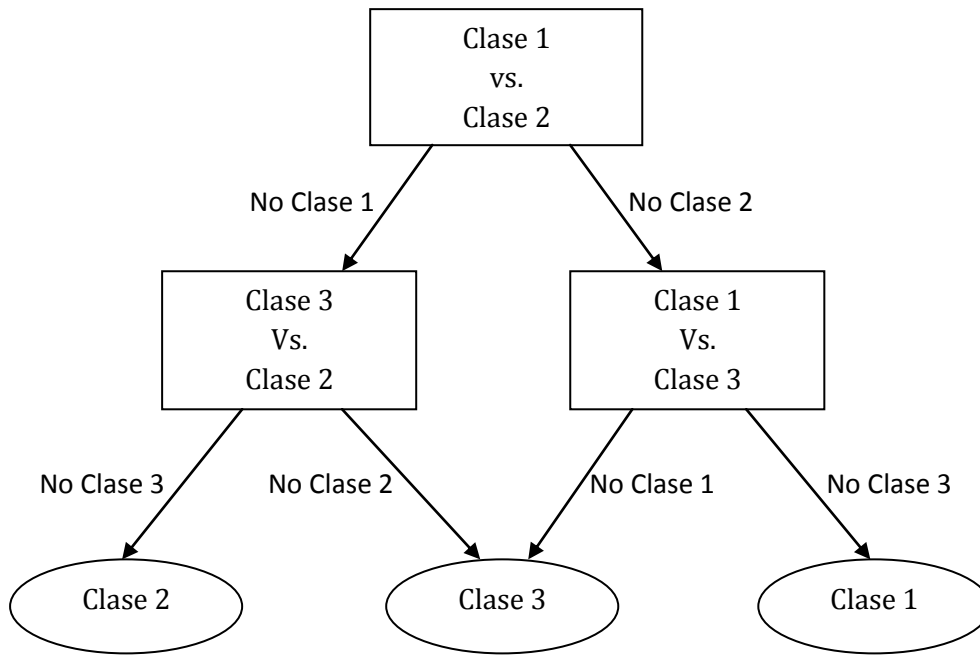


Figura 4.2. Lógica que sigue el algoritmo de clasificación 1-vs-r [31].

La mayor dificultad que nos encontramos ante este tipo de clasificación es que tanto las funciones de Libsvm como las propias de MATLAB® para el entrenamiento de las máquinas de soporte vectorial, no nos permiten dibujar los gráficos para mostrar cómo se modifican los vectores soporte en función de sus parámetros propios, siempre que el número de clases sea mayor que dos. Por ello se opta por usar los parámetros con los valores por defecto cuyos resultados en la mayoría de las ocasiones son aceptables.

4.1.2. Clasificación multiclase 1-vs-1

En la clasificación “uno contra uno” (1-vs-1), lo que se pretende es hacer una clasificación binaria donde la clase de los datos de test sea la clase positiva y el resto de las clases sean negativas. Esta definición, da lugar a dos posibles interpretaciones: la primera, asignamos la clase buscada como positiva y la enfrentamos a cada una de las otras clases por separado a las que asignamos como negativas (figura 4.3). De esta manera sólo habrá dos clases en cada comparación (sólo se utilizan muestras de esas dos clases para el entrenamiento), por lo que a diferencia del algoritmo para clasificación “uno contra el resto” (1-vs-r), nos permite modificar los parámetros en cada entrenamiento para optimizar la clasificación. Se realiza un proceso sucesivo hasta comparar la clase que buscamos con las demás, siguiendo una lógica similar a la que se muestra en la figura 4.2. La segunda, asignamos igualmente a la clase buscada la etiqueta de positiva y a todas las demás las etiquetamos como negativas. A diferencia de la primera interpretación, en ésta se enfrenta la etiqueta positiva al grupo formado por todas las otras clases que etiquetamos como negativas (se utilizan las muestras de todas las clases para el

entrenamiento pero únicamente se etiquetan como dos clases: positiva y negativa (figura 4.4)). Son dos maneras diferentes de entrenar el algoritmo.




Figura 4.3. Representación de las muestras que introducimos dos a dos para el entrenamiento y sus hiperplanos separadores para la clasificación "uno contra uno" (1-vs-1).




Figura 4.4. Representación de las muestras que utilizamos para el entrenamiento y su hiperplano separador para la clasificación "uno contra uno" (1-vs-1).

4.2. Sistema de clasificación

En este apartado desarrollamos el método seguido para el diseño del sistema de clasificación. Se ha utilizado la librería específica Libsvm para MATLAB® que nos proporciona las herramientas para entrenar la máquina de soporte vectorial y posteriormente clasificar los datos.

Para todos los casos, se coge el 75% de los datos para entrenamiento y el 25% restante para test (ver figura 4.5).




Figura 4.5. Representación de la metodología empleada para la extracción de las muestras para entrenamiento y test.

Se ha escogido esta distribución de los datos únicamente teniendo en cuenta que para los datos de test no se debía escoger ni datos del inicio, ni del final puesto que éstos podrían tener variaciones debido al arranque o parada del motor.

Para el entrenamiento y la clasificación, se realiza una descomposición en paquetes wavelet con un nivel de descomposición de tres, obteniendo ocho paquetes. De cada descomposición, se ha decidido utilizar únicamente cinco paquetes de los ocho. Se ha observado que son cinco paquetes en concreto los que tienen mayor variación en su nivel de energía según el tamaño y el tipo de defecto. Como lo que se introduce a la máquina de soporte vectorial son vectores de dos componentes, éstos estarán formados por una primera componente que contiene la energía del paquete wavelet y la segunda componente será el número de paquete wavelet al que corresponde dicho nivel de energía.

4.2.1. Clasificación uno contra el resto

En este tipo de clasificación, utilizamos el conjunto de los datos de entrenamiento para obtener una única salida de cada una de las muestras, es decir, obtendremos del 75% de la muestra que utilizamos para el entrenamiento, únicamente un valor de cada uno de los cinco vectores característicos que elegimos anteriormente (correspondientes a los

paquetes wavelet 1, 2, 3, 4 y 7) para cada tamaño de defecto. Podemos ver un esquema de cómo se entrena la máquina de soporte vectorial con este procedimiento en la figura 4.6. Comprobaremos si es suficiente un único valor de cada vector característico para entrenar la máquina de soporte vectorial y clasificar adecuadamente.

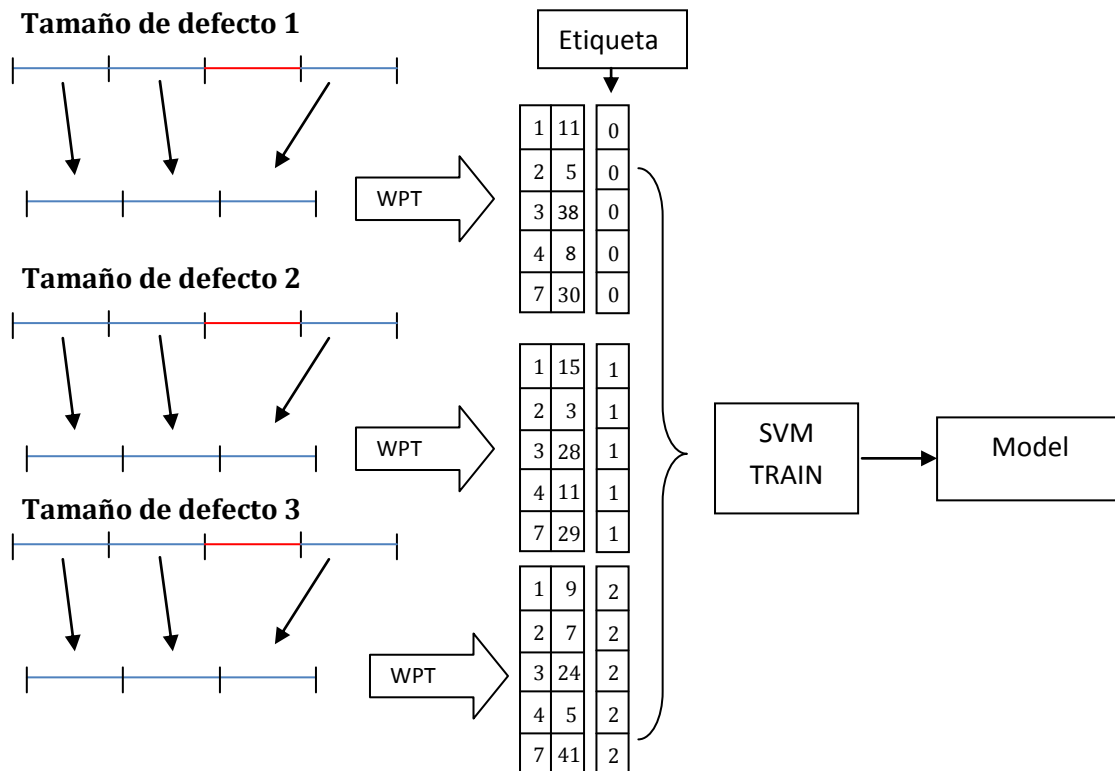


Figura 4.6. Esquema de los pasos a seguir para el entrenamiento de la máquina de soporte vectorial para hacer una clasificación multiclase 1-vs-r con un único valor de cada vector característico.

Para empezar, se prueba a entrenar la máquina de soporte vectorial para clasificar los datos en función del tamaño de defecto para un único tipo de defecto. Se etiquetan los datos dando el valor de 0 al tamaño de 0,007", 1 para el tamaño de 0,014", 2 para el tamaño de 0,021" y 3 para el tamaño de 0,028". Para el test, se escoge una clase cada vez y se prueba para ver qué resultados obtenemos (ver tabla 4.1). Con este tipo de clasificación no podemos hacer una representación en plano de los datos puesto que la función svmtoy de la librería específica Libsvm no permite hacer representaciones de datos con más de dos clases. Utilizaremos una función gaussiana (RBF, del inglés *radial basis function*) como kernel cuyo parámetro es Gamma. Como no podemos hacer representación de los datos, la modificación de los parámetros C y Gamma es mucho más costosa por lo que los dejaremos con los valores por defecto (C=1, Gamma=1).

Tipo de defecto	Tamaño de defecto	Etiqueta	Kernel utilizado	Gamma	C
Bola	0,007"	0	RBF	1	1
Bola	0,014"	1	RBF	1	1
Bola	0,021"	2	RBF	1	1
Bola	0,028"	3	RBF	1	1

Tabla 4.1. Resumen de parámetros y etiquetas utilizados para la clasificación "uno contra el resto" (1-vs-r).

El tanto por ciento que se muestra en las siguientes tablas representa el número de vectores bien clasificados (tasa de acierto del sistema clasificador). Puesto que introducimos únicamente cinco vectores para la clasificación, el porcentaje de acierto corresponde a cuántos de los vectores que introducimos de test son bien clasificados y por ello, sólo nos podemos encontrar seis soluciones distintas: 0%, 20%, 40%, 60%, 80% y 100%. Podemos ver una representación del proceso de clasificación en la figura 4.7.

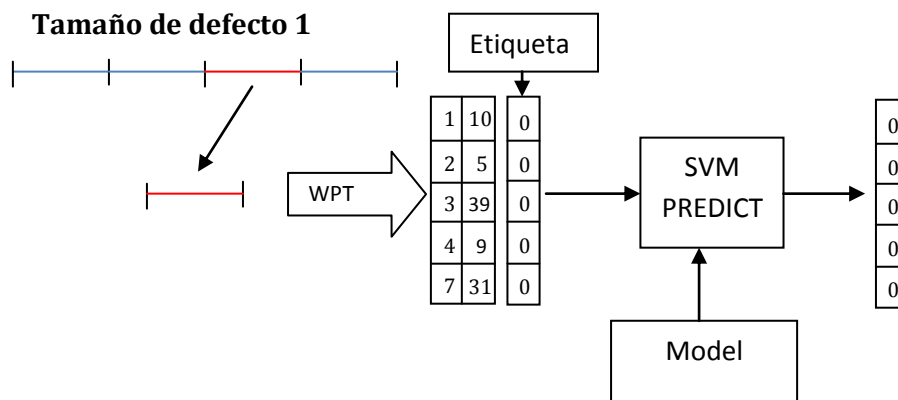


Figura 4.7. Representación de los pasos a seguir para la clasificación de una muestra en función del modelo obtenido en el entrenamiento anterior.

Los resultados obtenidos se muestran en la tabla 4.2.

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		80%	60%	40%	100%
Pista Interna		100%	80%	100%	80%
Pista Externa		100%	100%	100%	*

(*) No hay datos

Tabla 4.2. Resultados obtenidos en la clasificación "uno contra el resto" (1-vs-r) introduciendo tanto para el entrenamiento como para la clasificación un valor de cada vector característico.

A continuación, se entrenó la máquina de soporte vectorial para distinguir entre los diferentes tipos de defecto obteniendo los resultados que encontramos en la tabla 4.3.

Datos para entrenamiento:	Datos para test:	Bola/PI*/PE*	Bola/PI*/PE*	Bola/PI*/PE*
Bola		100%	-	-
Pista Interna		-	80%	-
Pista Externa		-	-	100%

*PI=Pista Interna; PE=Pista Externa

Tabla 4.3. Resultados obtenidos en la clasificación de señales de rodamiento con diferente tipo de defecto.

Como se puede observar, a pesar de utilizar únicamente cinco vectores para caracterizar cada clase los resultados obtenidos son aceptables. Tanto para los datos con defecto de pista externa, donde la probabilidad de acierto es del 100% en todos los casos, como para pista interna, obtenemos buenos resultados y por lo tanto podrían ser utilizados para una clasificación sin cometer grandes errores. En el caso de los datos con defecto en bola, se puede apreciar que sólo en el caso de mayor tamaño de defecto es capaz de clasificarlo correctamente por lo que con porcentajes por debajo del 80% podría llevarnos a cometer errores de clasificación.

Por otra parte, si introducimos cinco vectores para cada tipo de defecto en el entrenamiento, es capaz de clasificar con muy buen porcentaje de acierto el tipo de defecto por lo que para este tipo de análisis con estos únicos cinco vectores seríamos capaces de realizar una clasificación correcta.

Ahora probaremos la misma técnica (uno contra el resto), pero introduciendo mas vectores de entrenamiento. Se espera que aportando más valores a cada vector característico, la máquina de soporte vectorial sea capaz de separar las clases mejor al aportarle más información. Para ello, se obtienen los vectores para entrenamiento igualmente del 75% del total de los datos, pero dividiendo este 75% en tres partes y obteniendo cinco vectores de cada sección, de manera que cada clase quede definida por un total de quince vectores o lo que es lo mismo, obtenemos tres valores de cada vector característico que introduciremos en la etapa de entrenamiento.

Los resultados que obtenemos se muestran en la tabla 4.4.

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		100%	80%	40%	100%
Pista Interna		100%	60%	100%	80%
Pista Externa		100%	100%	100%	*

(*)No hay datos

Tabla 4.4. Resultados de la clasificación "uno contra el resto" empleando tres valores de cada vector característico para el entrenamiento.

A continuación se entrena la máquina de soporte vectorial para distinguir entre los diferentes tipos de defecto cuyos resultados se muestran en la tabla 4.5.

Datos para entrenamiento:	Datos para test:	Bola/PI*/PE*	Bola/PI*/PE*	Bola/PI*/PE*
Bola		100%	-	-
Pista Interna		-	100%	-
Pista Externa		-	-	100%

*PI=Pista Interna; PE=Pista Externa

Tabla 4.5. Resultados de la clasificación uno contra el resto para distinguir señales con distinto tipo de defecto utilizando tres valores de cada vector característico para el entrenamiento.

Como se podía esperar, cuando utilizamos tres valores de cada vector característico para caracterizar cada clase, cada una de las clases queda mejor definida y es más fácil que la máquina de soporte vectorial sea capaz de establecer mejores márgenes entre clases y por lo tanto que la posterior clasificación tenga mayor probabilidad de acierto. Se ha de tener en cuenta que aumentando el número de valores que se introducen de los vectores característicos no siempre nos ofrecerá mejores resultados en la clasificación. En este caso, utilizar más de tres valores para cada vector característico no ofrecía mejores resultados que con tres, por lo se descartó seguir añadiendo más valores para el entrenamiento.

El caso de defecto en bola para el tamaño de defecto de 0,021" es llamativo puesto que el tanto por ciento de acierto no varía a pesar de tener más vectores soporte para definir cada clase. Una de las razones que podemos encontrar es que los datos muestran una gran disparidad en los valores de energía, además en algunos de ellos (al menos cinco de quince) son muy cercanos a los valores que obtenemos para un tamaño de defecto de 0,028".

Puesto que estos resultados son mejores que los obtenidos anteriormente, probamos esta misma técnica, utilizando tres valores de cada uno de los vectores característicos para definir cada clase, utilizando los datos para distintas velocidades de rotación del motor.

Los datos de los que disponemos para la realización del estudio están recogidos para cuatro velocidades de rotación diferentes: 1797 rpm., 1772 rpm., 1750 rpm. y 1730 rpm.. El estudio inicial está realizado para la velocidad de rotación de 1797 rpm por lo que a continuación se muestran en las tablas 4.6, 4.7, 4.8, 4.9, 4.10 y 4.11 los resultados obtenidos para las diferentes velocidades de rotación.

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		60%	40%	80%	80%
Pista Interna		80%	100%	100%	100%
Pista Externa		80%	80%	80%	*

(*)No hay datos

Tabla 4.6. Resultados de la clasificación "uno contra el resto" empleando tres valores de cada vector característico para el entrenamiento para la velocidad de 1772 rpm.

Datos para entrenamiento:	Datos para test:	Bola/PI*/PE*	Bola/PI*/PE*	Bola/PI*/PE*
Bola		100%	-	-
Pista Interna		-	100%	-
Pista Externa		-	-	100%

*PI=Pista Interna; PE=Pista Externa

Tabla 4.7. Resultados de la clasificación uno contra el resto para distinguir señales con distinto tipo de defecto utilizando tres valores de cada vector característico para el entrenamiento para la velocidad de 1772 rpm.

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		100%	100%	100%	100%
Pista Interna		100%	100%	60%	100%
Pista Externa		100%	80%	80%	*

(*) No hay datos

Tabla 4.8. Resultados de la clasificación "uno contra el resto" empleando tres valores de cada vector característico para el entrenamiento para la velocidad de 1750 rpm.

Datos para entrenamiento:	Datos para test:	Bola/PI*/PE*	Bola/PI*/PE*	Bola/PI*/PE*
Bola		100%	-	-
Pista Interna		-	100%	-
Pista Externa		-	-	80%

*PI=Pista Interna; PE=Pista Externa

Tabla 4.9. Resultados de la clasificación uno contra el resto para distinguir señales con distinto tipo de defecto utilizando tres valores de cada vector característico para el entrenamiento para la velocidad de 1750 rpm.

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		100%	80%	100%	100%
Pista Interna		100%	60%	100%	100%
Pista Externa		100%	100%	80%	*

(*) No hay datos

Tabla 4.10. Resultados de la clasificación "uno contra el resto" empleando tres valores de cada vector característico para el entrenamiento para la velocidad de 1730 rpm.

Datos para entrenamiento:	Datos para test:	Bola/PI*/PE*	Bola/PI*/PE*	Bola/PI*/PE*
Bola		100%	-	-
Pista Interna		-	100%	-
Pista Externa		-	-	100%

*PI=Pista Interna; PE=Pista Externa

Tabla 4.11. Resultados de la clasificación uno contra el resto para distinguir señales con distinto tipo de defecto utilizando tres valores de cada vector característico para el entrenamiento para la velocidad de 1730 rpm.

A pesar de que las diferencias de velocidades de rotación entre los diferentes ensayos son pequeñas, se puede apreciar que hay variación en las tasas de acierto. En los resultados no se observa una tendencia clara a fallar en una clasificación concreta, por lo que podemos achacar estas variaciones a la aleatoriedad al escoger la muestra de datos para la clasificación y a que no estamos utilizando un margen blando, que nos permitiera que durante el entrenamiento no se tuvieran en cuenta los datos atípicos para la determinación de la frontera de decisión.

En cuanto al método utilizado, podemos concluir que utilizando tres valores para cada vector característico que definen cada clase, conseguimos mejores resultados que con sólo uno, pero siguen siendo clasificaciones que pueden llevarnos a error puesto que tenemos porcentajes por debajo del 60% en más de un caso para un mismo tipo de defecto. Para clasificar datos con diferentes tipos de defecto podríamos utilizarlo sin cometer errores.

Se ha de tener en cuenta, que para una clasificación correcta del tipo de defecto de una muestra concreta, se debería realizar un análisis posterior a la clasificación para determinar cuáles de los vectores característicos (de los cinco que utilizamos para entrenar la máquina) son clasificados correctamente siempre y usarlos como factores de decisión. Las tasas de acierto que se muestran, nos dan una referencia de si los datos son separables adecuadamente y conseguir porcentajes del 80% nos proporciona al menos tres vectores característicos que se van a clasificar bien.

Para que cualquier clasificación se realizara maximizando el porcentaje de acierto de acuerdo a los datos de entrenamiento de los que disponemos, deberíamos modificar los valores de C y Γ para que los vectores soporte sean capaces de separar las clases lo mejor posible. Para clasificación multiclase, variar los parámetros no es sencillo puesto que la función `svmtrain` está diseñada para realizar clasificaciones binarias y al modificar estos valores se los modificaríamos a todos los vectores soporte. Esto en algunos casos funcionaría bien y en otros nos dificultaría la correcta clasificación puesto que son parámetros individuales a cada una de las comparaciones entre dos clases distintas.

4.2.2. Clasificación uno contra uno

En este tipo de clasificación enfrentaremos cada clase contra cada una de las demás por separado, considerando la búsqueda positiva y cada una de las enfrentadas negativas.

Empezamos con la clasificación enfrentando uno contra uno buscando las mejores condiciones posibles de clasificación, es decir, buscaremos los parámetros óptimos para la clasificación.

Para ello, se muestra en la figura 8, las combinaciones de los parámetros γ y C de manera que consigamos visualizar cuáles serán los óptimos para que la clasificación obtenga los mejores resultados posibles. Puesto que la elección de los parámetros se hace antes de introducir los valores de test, lo que hacemos es ver si nuestro número de datos de entrenamiento es suficiente y si los valores que obtenemos de los vectores que

contienen la energía de los paquetes wavelet están bien situados dentro de los márgenes que establece la frontera de decisión (hiperplano separador).

Para ilustrar un ejemplo de esto, utilizaremos los dos métodos utilizados anteriormente para el entrenamiento y la clasificación: primero, introducimos los cinco vectores característicos con un solo valor de cada uno de ellos, para representar cada una de las clases (tipo de defecto o tamaño de defecto) y después, introduciremos tres valores de cada uno de los vectores característicos para cada clase de manera que mediante la representación gráfica mencionada anteriormente, seamos capaces de ver si realmente merece la pena usar más vectores característicos para caracterizar cada clase o si de lo contrario los resultados apenas varían.

Se elige un tipo de defecto, que en este caso será defecto en bola por ser el defecto que en los estudios anteriores arrojó peores resultados, e introducimos dos tamaños de defecto que en este caso serán el de 0,007" y 0,021" por ser los que peor era capaz de clasificar por dar valores de sus vectores característicos similares.

En la figura 4.8, se muestra la relación entre los parámetros Gamma y C utilizando cinco vectores característicos:




Figura 4.8. Representación mediante la escala de colores de la precisión en la separación de las clases en función de los valores de los parámetros Gamma y C, entrenando con un valor de cada vector característico.

Como se puede observar, la precisión esperada para la clasificación será de un 40% siempre y cuando utilicemos los valores óptimos de Gamma y C.

Ahora realizamos la clasificación en primer lugar, sin variar los parámetros y después introduciendo los valores óptimos, donde la etiqueta '0' corresponde al tamaño de defecto de 0,007" y la etiqueta '1' corresponde al tamaño de defecto de 0,021", obteniendo los resultados que se muestran a continuación tal y como nos los devuelve el programa:

1. Cuando introducimos como test una muestra de defecto de 0,007”:

1.1. Parámetros por defecto: Accuracy = 80% (4/5) (classification)
predicted_label = (0, 0, 1, 0, 0)

1.2. Parámetros óptimos: Accuracy = 60% (3/5) (classification)
predicted_label = (0, 0, 1, 1, 0)

2. Cuando introducimos como test una muestra de defecto de 0,021”:

2.1. Parámetros por defecto: Accuracy = 40% (2/5) (classification)
predicted_label = (1, 0, 0, 0, 1)

2.2. Parámetros óptimos: Accuracy = 40% (2/5) (classification)
predicted_label = (1, 0, 0, 0, 1)

Ahora volvemos a seguir los mismos pasos pero introduciendo tres valores de cada vector característico por cada tamaño de defecto. En la figura 4.9, se muestra la relación entre los parámetros Gamma y C utilizando tres valores de cada vector característico:




Figura 4.9. Representación mediante la escala de colores de la precisión en la separación de las clases en función de los valores de los parámetros Gamma y C entrenando con tres valores de cada vector característico.

Como se puede observar en la figura 4.9, en este caso la precisión esperada para los datos de entrenamiento será de un 76,67% cuando utilizemos los valores óptimos de Gamma y C.

Ahora realizamos la clasificación primero sin variar los parámetros y después introduciendo los valores óptimos, donde la etiqueta '0' corresponde al tamaño de defecto de 0,007" y la etiqueta '1' corresponde al tamaño de defecto de 0,021", obteniendo los resultados que se muestran a continuación tal y como los devuelve el programa:

1. Cuando introducimos como test una muestra de defecto de 0,007”:

1.1. Parámetros por defecto: Accuracy = 100% (5/5) (classification)

predicted_label = (0, 0, 0, 0, 0)

1.2. Parámetros óptimos: Accuracy = 100% (5/5) (classification)

predicted_label = (0, 0, 0, 0, 0)

Donde la etiqueta ‘0’ corresponde al tamaño de defecto de 0,007” y la etiqueta ‘1’ corresponde al tamaño de defecto de 0,021”.

2. Cuando introducimos como test una muestra de defecto de 0,021”:

2.1. Parámetros por defecto: Accuracy = 20% (1/5) (classification)

predicted_label = (0, 0, 0, 0, 1)

2.2. Parámetros óptimos: Accuracy = 40% (2/5) (classification)

predicted_label = (1, 0, 0, 0, 1)

Estos resultados nos confirman la premisa inicial. En la primera parte donde introducimos únicamente un valor de cada vector característico para cada clase, los resultados obtenidos no solo no mejoran con la optimización de los parámetros Gamma y C sino que empeoran. Esto se debe a que la precisión esperada para este estudio era de un 40% por lo que algunas clases no quedaban bien separadas y al aplicarle un margen blando, elimina las muestras que quedaran dentro de los márgenes provocando que en casos concretos se clasifique peor. En la segunda parte vemos como los resultados mejoran al menos hasta el máximo de las posibilidades que nos ofrecían estos datos.

Podemos concluir que el entrenamiento mediante únicamente un valor de cada vector característico no es suficiente para obtener buenos resultados y por ello, utilizaremos tres valores de cada vector característico para el análisis completo.

Se analizarán las señales enfrentándolas mediante la clasificación “uno contra uno” (1-vs-1) optimizando los valores de los parámetros Gamma y C. En las tablas 4.12, 4.13 y 4.14 se muestran las tasas de acierto obtenidas en las diferentes clasificaciones.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007” 0,014”	0,007” 0,021”	0,007” 0,028”
0,007”	100%	100%	100%
	0,014” 0,007”	0,014” 0,021”	0,014” 0,028”
0,014”	60%	100%	100%
	0,021” 0,007”	0,021” 0,014”	0,021” 0,028”
0,021”	40%	60%	100%
	0,028” 0,007”	0,028” 0,014”	0,028” 0,021”
0,028”	100%	100%	100%

Tabla 4.12. Tasas de acierto obtenidas al enfrentar muestras con defecto en bola y distinto tamaño de defecto con clasificación “uno contra uno” (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	100%	100%	100%
	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
0,014"	80%	60%	80%
	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
0,021"	100%	100%	100%
	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
0,028"	100%	80%	100%

Tabla 4.13. Tasas de acierto obtenidas al enfrentar muestras con defecto en pista interna y distinto tamaño de defecto con clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	100%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.14. Tasas de acierto obtenidas al enfrentar muestras con defecto en pista externa y distinto tamaño de defecto con clasificación "uno contra uno" (1-vs-1).

A pesar de que en éste análisis no se obtengan en todos los casos tasas de acierto del 100%, si analizamos dos a dos, se puede ver que siempre podríamos determinar el tamaño de defecto de la muestra sin cometer error.

Para el caso de la detección del tipo de defecto, los resultados que obtenemos se muestran en la tabla 4.15.

Datos para test:	Datos para entrenamiento:	Bola/Pista interna	Pista externa/Pista Interna	Bola/Pista Externa
Bola		100%	-	100%
Pista Interna		100%	100%	-
Pista Externa		-	100%	100%

Tabla 4.15. Tasas de acierto obtenidas al enfrentar muestras con distinto defecto con clasificación "uno contra uno" (1-vs-1).

A la vista de los resultados obtenidos en este análisis podemos concluir que, a partir de tres valores para cada vector característico, el método es suficientemente consistente para tener resultados aceptables.

4.3. Determinación del tamaño mínimo de datos representativo para la clasificación

El nuevo análisis que se va a realizar, consiste en determinar aproximadamente el número mínimo de datos necesarios para que el entrenamiento y su posterior clasificación se puedan realizar correctamente (con porcentajes de acierto elevados). Al escoger un número de datos menor, la disparidad en los resultados debería ser mayor y por ello dificultaría la clasificación.

Se establecen como límites inferior y superior, el número de datos necesarios para recoger cuatro vueltas completas del rodamiento y el número total de datos recogidos en todo el ensayo respectivamente.

Para el límite inferior, se escogen cuatro vueltas completas del rodamiento debido a que seguiremos utilizando el mismo método de entrenamiento y clasificación utilizado anteriormente. Dividimos los datos entre cuatro para obtener los vectores característicos de cada una de las partes, las cuales, constarán mínimo de los datos recogidos durante una vuelta completa del rodamiento y que por lo tanto nos asegura que el defecto en el rodamiento haya completado una vuelta y pueda verse reflejado en los resultados.

Todos los archivos de datos que se han utilizado para los anteriores análisis, se ha comprobado que dividiendo el número de datos entre sesenta y cuatro, se consigue un número de datos muy próximo al número de datos mínimo que completan una vuelta del rodamiento, que fue el límite inferior propuesto anteriormente.

La metodología que seguiremos será dividir el número total de datos entre dos en cada prueba, mostrando los resultados en cada paso. Al final intentaremos extraer los posibles patrones que aparezcan según se disminuye el número de datos.

Se utilizan las muestras con el defecto en pista externa por ser el defecto que mejor se clasifica con todos los datos y de esta manera podamos ver si al variar el número de datos la clasificación deja de ser correcta.

En la tabla 4.16, se muestran los resultados obtenidos al reducir a la mitad el tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	100%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.16. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la mitad.

En todas las comparaciones se ha conseguido un 100% de precisión estimada por lo que no hay variación respecto al análisis inicial. En la tabla 4.17, se muestran los resultados obtenidos al reducir a la cuarta parte el tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	100%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.17. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la cuarta parte.

Por primera vez, obtenemos precisión de los datos por debajo del 100% (ésta precisión se corresponde con la que obtenemos en el gráfico que relaciona los parámetros C y Gamma con la precisión esperada) al enfrentar los tamaños de defecto de 0,007" y 0,021" y cuando enfrentamos 0,014" y 0,021" pero como tenemos precisiones del 93% y 96% respectivamente todavía es capaz de clasificar correctamente. En la tabla 4.18, se muestran los resultados obtenidos al reducir a la octava parte el tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	80%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.18. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la octava parte.

Para este número de datos, podemos apreciar en los resultados que hay una muestra que no es capaz de clasificar correctamente al 100% pero que en general las clasificaciones son correctas. En todos los casos la precisión ha disminuido considerablemente, puesto la gran mayoría ya no es del 100% y en el caso de la que enfrenta a los defectos de 0,014" y 0,021" la precisión era de un 90%. En la tabla 4.19, se muestran los resultados obtenidos al reducir a la dieciseisava parte el tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	80%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	100%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.19. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la dieciseisava parte.

Al igual que en el caso anterior, las precisiones disminuyeron frente a las iniciales pero no hay un gran cambio en el porcentaje de clasificaciones correctas respecto a la clasificación anterior. En la tabla 4.20, se muestran los resultados obtenidos al reducir a la treintaidosava parte el tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	80%	20%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	60%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.20. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la treintaidosava parte.

Podemos observar como el porcentaje de acierto en las clasificaciones ha disminuido considerablemente. Nos encontramos en un punto donde estamos extrayendo los valores característicos de datos que comprenden aproximadamente dos vueltas completas del rodamiento.

Hacemos el último análisis extrayendo los datos de tan solo una vuelta del rodamiento cuyos resultados se muestran en la tabla 4.21 y corresponden a la reducción de la sesentaicuatroava parte del tamaño de datos de la muestra.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	80%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	60%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	80%

Tabla 4.21. Tasas de acierto obtenidas al reducir el número de datos de la muestra a la sesentaicuatroava parte

A pesar de que los porcentajes aumentan respecto al análisis anterior, no es relevante porque la precisión obtenida en cada una de las comparaciones realizadas se ha mantenido e incluso ha disminuido, por lo que al tratarse de datos diferentes los que se escogen para test, se puede tratar de una caso en el que los datos se sitúan mejor dentro de los márgenes que establecen los vectores soporte.

Como conclusión a este análisis, se extrae que a partir de un número de datos en torno a la octava parte del total, los datos que utilizamos no son suficientes para extraer los vectores característicos que caracterizan con los parámetros esperados a cada clase. Cualquier variación podría suponer un gran cambio en el resultado final por tener precisiones por debajo del 90%. Esto indica que no hay datos suficientes como para que en la media total se refleje lo que realmente ocurre para cada clase.

4.4. Pruebas de robustez del método

Para probar la robustez del método empleado anteriormente, se añade ruido blanco a la señal con distintos niveles de ruido utilizando dos tipos de clasificación. Por un lado se realiza el primer tipo de clasificación realizado, la de "uno contra el resto" (1-vs-r) utilizando tres valores de cada vector característico para caracterizar cada clase y por otro lado utilizaremos la clasificación "uno contra uno" (1-vs-1), también utilizando tres valores de cada vector característico, buscando los valores óptimos de los parámetros Gamma y C y realizando los entrenamientos con ellos. Utilizaremos estas muestras con ruido tanto para el entrenamiento como para la clasificación.

Se empezó con un nivel de ruido que no superara el 20% del máximo de la señal sin ruido y se llegó hasta un máximo del 60% del máximo de la señal sin ruido.

4.4.1. Prueba de robustez. Clasificación 1-vs-r.

Para nivel de ruido de un máximo del 20% del máximo de la señal sin ruido

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		80%	80%	80%	100%
Pista Interna		80%	60%	100%	100%
Pista Externa		100%	100%	100%	*

(*)No hay datos

Tabla 4.22. Tasas de acierto obtenidas añadiendo ruido blanco a la señal con una amplitud máxima del 20% del máximo de la señal sin ruido mediante la clasificación "uno contra el resto" (1-vs-r).

Para nivel de ruido de un máximo del 40% del máximo de la señal sin ruido

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		100%	100%	40%	100%
Pista Interna		80%	80%	100%	100%
Pista Externa		100%	100%	60%	*

(*)No hay datos

Tabla 4.23. Tasas de acierto obtenidas añadiendo ruido blanco a la señal con una amplitud máxima del 40% del máximo de la señal sin ruido mediante la clasificación "uno contra el resto" (1-vs-r).

Para nivel de ruido de un máximo del 60% del máximo de la señal sin ruido

Defecto en:	Datos para test:	0,007"	0,014"	0,021"	0,028"
Bola		100%	100%	80%	100%
Pista Interna		80%	100%	100%	100%
Pista Externa		100%	80%	80%	*

(*)No hay datos

Tabla 4.24. Tasas de acierto obtenidas añadiendo ruido blanco a la señal con una amplitud máxima del 60% del máximo de la señal sin ruido mediante la clasificación "uno contra el resto" (1-vs-r).

Como se puede observar en los resultados, un ruido blanco con picos de hasta un 60% del máximo de la señal no es capaz de distorsionar la señal lo suficiente como para obtener resultados anómalos. La razón principal por la que ocurre esto se debe al filtrado que realiza la WPT. Los resultados apenas varían respecto a la señal sin ruido.

4.4.2. Prueba de robustez. Clasificación 1-vs-1.

Para nivel de ruido de un máximo del 20% del máximo de la señal sin ruido

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	80%	100%	100%
0,014"	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
	100%	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
	100%	20%	100%
0,028"	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
	100%	100%	100%

Tabla 4.25. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en bola con una amplitud máxima del 20% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	80%	100%	100%
0,014"	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
	60%	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
	100%	100%	100%
0,028"	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
	100%	100%	100%

Tabla 4.26. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista interna con una amplitud máxima del 20% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	80%
0,014"	0,014" 0,007"	0,014" 0,021"
	100%	80%
0,021"	0,021" 0,007"	0,021" 0,014"
	100%	100%

Tabla 4.27. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista externa con una amplitud máxima del 20% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Para nivel de ruido de un máximo del 40% del máximo de la señal sin ruido

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	100%	100%	100%
	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
0,014"	100%	100%	100%
	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
0,021"	100%	40%	100%
	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
0,028"	80%	100%	100%

Tabla 4.28. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en bola con una amplitud máxima del 40% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	80%	80%	60%
	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
0,014"	80%	100%	100%
	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
0,021"	100%	100%	100%
	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
0,028"	100%	100%	100%

Tabla 4.29. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista interna con una amplitud máxima del 40% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	80%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.30. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista externa con una amplitud máxima del 40% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Para nivel de ruido de un máximo del 60% del máximo de la señal sin ruido

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	100%	100%	100%
0,014"	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
	100%	80%	100%
0,021"	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
	100%	40%	80%
0,028"	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
	100%	100%	100%

Tabla 4.31. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en bola con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	80%	80%	100%
0,014"	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
	80%	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
	100%	100%	100%
0,028"	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
	80%	100%	80%

Tabla 4.32. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista interna con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	80%	100%
0,014"	0,014" 0,007"	0,014" 0,021"
	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"
	100%	40%

Tabla 4.33. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista externa con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Al igual que en el caso anterior, en la clasificación “uno contra uno” (1-vs-1) el ruido blanco que hemos añadido a la señal tampoco es capaz de distorsionar los resultados lo suficiente como para que los resultados varíen significativamente.

Queda comprobado que el método de clasificación mediante la transformación en paquetes wavelet y su posterior entrenamiento mediante máquina de soporte vectorial es capaz de soportar un nivel de ruido elevado sin que los resultados varíen significativamente.

5. Aplicación a defectos incipientes.

En el presente capítulo, vamos a utilizar el método desarrollado en el capítulo 4 para el análisis de señales de rodamientos con defectos incipientes.

Las muestras de datos que vamos a utilizar son los mismos utilizados en [12, 23, 24] y todo lo relativo a cómo se han tomado los datos y las características de los rodamientos y el banco de ensayo, está recogido en [12].

El análisis que se va a realizar consistirá en utilizar la máquina de soporte vectorial como método de clasificación con el propósito de clasificar correctamente señales que tienen diferentes tipos de defectos incipientes (defecto en bola, defecto en pista interna y defecto en pista externa).

Tenemos datos para tres velocidades de giro diferentes (600 rpm, 1200 rpm y 1800 rpm) de rodamiento sano, con defecto en bola, con defecto en pista interna y defecto en pista externa.

En las tablas que mostramos a continuación, en la columna de la izquierda se indica el tipo de defecto que contiene la señal de la cual cogemos la muestra para realizar el test y en cada una de las columnas pertenecientes a la sección tipo de defecto para entrenamiento, contienen el tipo de defecto con el cual se ha enfrentado la señal utilizada para test y con las cuales se ha entrenado la máquina de soporte vectorial obteniendo los parámetros óptimos e implementándolos en el entrenamiento.

5.1. Análisis para velocidad de giro de 600 rpm.

Tipo de defecto para test	Tipo de defecto para entrenamiento			
	Bola	Pista interna	Pista externa	Sano
Defecto en bola	-	100%	100%	100%
Defecto en pista interna	80%	-	100%	100%
Defecto en pista externa	80%	100%	-	80%
Sano	100%	100%	80%	-

Tabla 5.1. Tasas de acierto obtenidas para la identificación del tipo de defecto en señales de rodamientos con defectos incipientes para una velocidad de giro de 600 rpm.

Como se puede observar, en cualquiera de las comparaciones seríamos capaces de clasificar correctamente el tipo de defecto que contiene la señal.

A pesar de que aparecen algunos porcentajes de 80%, si vemos los gráficos de precisión (Anexo 4) para el cálculo de los parámetros Gamma y C, podemos ver que

conseguimos precisiones por encima del 90% sin la necesidad de utilizar valores del margen blando 'C' elevados, haciendo más evidente que este método es capaz de separar eficazmente las dos clases.

5.2. Análisis para velocidad de giro de 1200 rpm.

Tipo de defecto para test	Tipo de defecto para entrenamiento			
	Bola	Pista interna	Pista externa	Sano
Defecto en bola	-	80%	100%	100%
Defecto en pista interna	100%	-	80%	100%
Defecto en pista externa	80%	80%	-	100%
Sano	100%	100%	100%	-

Tabla 5.2. Tasas de acierto obtenidas para la identificación del tipo de defecto en señales de rodamientos con defectos incipientes para una velocidad de giro de 1200 rpm.

Los porcentajes de acierto que conseguimos con esta velocidad de giro son muy similares a los que obtuvimos para 600 rpm y al igual que en ésta, podemos clasificar correctamente cualquiera de las muestras.

Las precisiones que conseguimos para este análisis son por encima del 90% (Anexo 4) al igual que ocurría en el caso anterior, por lo que aumentar la velocidad de giro al doble no ha supuesto una dificultad para la correcta clasificación de las muestras.

5.3. Análisis para velocidades de giro de 1800 rpm.

Tipo de defecto para test	Tipo de defecto para entrenamiento			
	Bola	Pista interna	Pista externa	Sano
Defecto en bola	-	100%	100%	100%
Defecto en pista interna	60%	-	80%	100%
Defecto en pista externa	100%	100%	-	100%
Sano	100%	100%	100%	-

Tabla 5.3. Tasas de acierto obtenidas para la identificación del tipo de defecto en señales de rodamientos con defectos incipientes para una velocidad de giro de 1800 rpm.

En este caso, el porcentaje de acierto en el caso de la detección de un defecto en pista interna comprándolo con un defecto en bola está por debajo del 80%. En este análisis la precisión esperada era de un 80% por lo que se podía esperar un resultado así.

A pesar de ello, no se puede achacar este resultado al aumento de la velocidad de giro puesto que en el resto de análisis, la precisión era de un 100% (Anexo 4). Podemos sacar como conclusión a este dato que la muestra escogida para test de defecto en pista interna no sea representativa y por ello obtengamos un porcentaje de acierto por debajo de lo esperado o que el total de la muestra de defecto en pista interna para esta velocidad de giro tenga valores anómalos que dificulten el entrenamiento y la clasificación.

Para comprobar que se debe a una anomalía en la medida de esa muestra, hacemos el análisis para otras dos muestras de defecto en pista interna para ver si la premisa anterior es correcta.

Muestra 1:

Tipo de defecto para test	Tipo de defecto para entrenamiento		
	Bola	Pista externa	Sano
Defecto en pista interna	80%	80%	100%

Tabla 5.4. Tasas de acierto obtenidas para la muestra 1 de señales de rodamientos con defectos incipientes en pista interna para una velocidad de giro de 1800 rpm.

Muestra 2:

Tipo de defecto para test	Tipo de defecto para entrenamiento		
	Bola	Pista externa	Sano
Defecto en pista interna	80%	80%	100%

Tabla 5.5. Tasas de acierto obtenidas para la muestra 2 de señales de rodamientos con defectos incipientes en pista interna para una velocidad de giro de 1800 rpm.

Como podemos ver, al utilizar otras dos muestras del mismo rodamiento con el mismo tipo de defecto, conseguimos valores de acierto de al menos el 80% como era de esperar por el resto de resultados.

5.4. Análisis de los resultados

En los tres análisis realizados anteriormente, se han obtenido porcentajes de acierto en todos los casos por encima del 80% con precisiones en la separación de clases de más del 90% en prácticamente todos los casos y en la gran mayoría de un 100% (Ver anexo 4). Por ello podemos afirmar que las máquinas de soporte vectorial con la metodología empleada, son capaces de identificar el estado de los rodamientos aun tratándose de defectos incipientes con porcentajes de acierto muy elevados.

6. Conclusiones y futuros desarrollos

Como objetivos generales, se propusieron el análisis de señales mediante técnicas en el dominio de la frecuencia y en el dominio tiempo-frecuencia, además del uso de las máquinas de soporte vectorial como sistema de clasificación para el correcto diagnóstico de rodamientos de bola.

La conclusión que podemos extraer del desarrollo del presente PFC es que, el uso de técnicas en el dominio de la frecuencia no son adecuadas para caracterizar el estado de un rodamiento de bola. En el caso de las técnicas en el dominio tiempo-frecuencia, el uso de la WPT para la extracción de vectores característicos de las señales es capaz de devolvernos valores representativos de cada clase, lo que la hace una herramienta muy capacitada para ser utilizada junto a sistemas de clasificación inteligente.

En cuanto a las máquinas de soporte vectorial, se ha desarrollado un sistema de clasificación probando los diferentes análisis disponibles en las librerías utilizadas. Los resultados obtenidos nos muestran que las máquinas de soporte vectorial son capaces de separar correctamente los vectores característicos extraídos de las señales de rodamientos con diferentes tipos de defecto y tamaño de defecto, con porcentajes de acierto elevados, utilizando una función núcleo o kernel RBF y modificando el parámetro del margen blando C .

Se ha elaborado una guía de utilización de este sistema de clasificación para la detección de fallos en rodamientos de bola.

6.1. Conclusiones específicas

El análisis en el dominio de la frecuencia mediante la transformada de Fourier no es capaz de obtener buenos resultados en la identificación del estado de los rodamientos y por lo tanto no es un buen método para utilizarlo junto a sistemas de clasificación inteligentes. Factores como el ruido en la señal y las frecuencias características de diferentes elementos del motor, hacen muy difícil este tipo de análisis.

La utilización de la transformada en paquetes wavelet para caracterizar el estado de un rodamiento por su nivel de energía, es un método muy fiable y que se ajusta muy bien a los requisitos que se buscaban para utilizarlos junto a los sistemas de clasificación inteligentes.

A pesar del uso de únicamente cinco vectores, extraídos de la WPT, para caracterizar cada muestra, conseguimos porcentajes de acierto muy elevados, consiguiendo uno de nuestros objetivos que era tener un gasto computacional moderado.

La metodología utilizada en el presente PFC es capaz de diagnosticar la condición de un rodamiento de bolas en todos los casos propuestos. Mediante tres valores de cada vector característico somos capaces de clasificar correctamente todos los vectores característicos para determinar el tipo de defecto, como se muestra en la tabla 4.15.

Datos para test:	Datos para entrenamiento:	Bola/Pista interna	Pista externa/Pista Interna	Bola/Pista Externa
Bola		100%	-	100%
Pista Interna		100%	100%	-
Pista Externa		-	100%	100%

Tabla 4.15. Tasas de acierto obtenidas al enfrentar muestras con distinto defecto con clasificación “uno contra uno” (1-vs-1).

Para la clasificación de señales con un mismo tipo de defecto y diferentes tamaños de defecto, los resultados obtenidos nos muestran que las tasas de acierto más bajas se dan para los rodamientos con defecto en bola, como se muestra en la tabla 4.12, y las mejores tasas de acierto las encontramos en los rodamientos con defecto en pista externa, como se muestra en la tabla 4.14.

La lectura que podemos hacer de estos resultados, es que en cualquiera de los casos, obtener porcentajes de acierto elevados nos ofrece más posibilidades de diagnosticar correctamente el estado de un rodamiento en concreto. Si estableciéramos que únicamente se definieran las clases con un vector característico, siempre encontraríamos al menos dos vectores característicos (por tener en el peor de los casos un 40% de tasa de acierto (2/5)) con los que seríamos capaces de clasificar correctamente el estado del rodamiento. Si de lo contrario, el criterio se basara en los porcentajes de acierto respecto al total de los vectores característicos, que elegimos antes del análisis, igualmente nos encontramos con que a pesar de tener porcentajes del 40% o del 60%, al introducir la otra muestra como test, siempre obtenemos un 100%, por lo que por eliminación o descarte, podríamos diagnosticar el estado del rodamiento correctamente en todos los casos.

	Tamaño de defecto para entrenamiento		
Tamaño de defecto para test	0,007” 0,014”	0,007” 0,021”	0,007” 0,028”
0,007”	100%	100%	100%
	0,014” 0,007”	0,014” 0,021”	0,014” 0,028”
0,014”	60%	100%	100%
	0,021” 0,007”	0,021” 0,014”	0,021” 0,028”
0,021”	40%	60%	100%
	0,028” 0,007”	0,028” 0,014”	0,028” 0,021”
0,028”	100%	100%	100%

Tabla 4.12. Tasas de acierto obtenidas al enfrentar muestras con defecto en bola y distinto tamaño de defecto con clasificación “uno contra uno” (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	100%	100%
	0,014" 0,007"	0,014" 0,021"
0,014"	100%	100%
	0,021" 0,007"	0,021" 0,014"
0,021"	100%	100%

Tabla 4.14. Tasas de acierto obtenidas al enfrentar muestras con defecto en pista externa y distinto tamaño de defecto con clasificación "uno contra uno" (1-vs-1).

La utilización de la WPT y las SVM conjuntamente, permite manejar numerosas variables que hacen muy robusto el método permitiendo conseguir muy buena precisión en los resultados.

El uso de WPT permite analizar señales con niveles altos de ruido sin que haya una gran distorsión en los resultados. Esto quedó reflejado en las tablas 4.31, 4.32 y 4.33 donde se muestran los resultados obtenidos, al realizar las clasificaciones para muestras a las que se les añadió ruido blanco con una amplitud máxima de hasta el 60% del valor máximo de la señal sin ruido.

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	100%	100%	100%
	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
0,014"	100%	80%	100%
	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
0,021"	100%	40%	80%
	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
0,028"	100%	100%	100%

Tabla 4.31. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en bola con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento		
	0,007" 0,014"	0,007" 0,021"	0,007" 0,028"
0,007"	80%	80%	100%
0,014"	0,014" 0,007"	0,014" 0,021"	0,014" 0,028"
	80%	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"	0,021" 0,028"
	100%	100%	100%
0,028"	0,028" 0,007"	0,028" 0,014"	0,028" 0,021"
	80%	100%	80%

Tabla 4.32. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista interna con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Tamaño de defecto para test	Tamaño de defecto para entrenamiento	
	0,007" 0,014"	0,007" 0,021"
0,007"	80%	100%
0,014"	0,014" 0,007"	0,014" 0,021"
	100%	100%
0,021"	0,021" 0,007"	0,021" 0,014"
	100%	40%

Tabla 4.33. Tasas de acierto obtenidas añadiendo ruido blanco a la señal de rodamiento con defecto en pista externa con una amplitud máxima del 60% del máximo de la señal sin ruido mediante clasificación "uno contra uno" (1-vs-1).

Los resultados apenas varían respecto a los mismos análisis para las señales sin ruido.

Se ha demostrado que mediante el método planteado, no sólo somos capaces de diagnosticar rodamientos con un defecto acusado, sino que también somos capaces de diagnosticar rodamientos con defectos incipientes como queda reflejado en las tasas de acierto obtenidas en la tabla 5.1.

Tipo de defecto para test	Tipo de defecto para entrenamiento			
	Bola	Pista interna	Pista externa	Sano
Defecto en bola	-	100%	100%	100%
Defecto en pista interna	80%	-	100%	100%
Defecto en pista externa	80%	100%	-	80%
Sano	100%	100%	80%	-

Tabla 5.1. Tasas de acierto obtenidas para la identificación del tipo de defecto en señales de rodamientos con defectos incipientes para una velocidad de giro de 600 rpm.

6.2. Futuros desarrollos

Desde el proceso de adquisición de la señal hasta la clasificación, hay numerosas variables a tener en cuenta y la decisión de darles un valor determinado es la que nos ha llevado a obtener los resultados que se muestran en el presente PFC.

Como parte de la experiencia de la realización de este PFC, podemos añadir que algunas de las variables podrían ser modificadas buscando optimizar el método, las cuales enumeramos a continuación.

- Aumento de vectores característicos: debido al método que se propuso en este PFC, no era necesario más de cinco vectores característicos puesto que caracterizaban perfectamente el estado de los rodamientos de bola, pero quizás en otros casos el uso de niveles de descomposición mayores con el uso de más vectores característicos permitan clasificar mejor las muestras.
- Aumento de datos para el entrenamiento: en el método propuesto, tan sólo utilizábamos 3 valores de cada vector característico en cada clase, lo cual puede ser insuficiente en algunos casos.
- Función núcleo o kernel: el uso de la función RBF en nuestro método se debe a que se recomienda en [21] la utilización de este tipo de función para este tipo de clasificaciones, pero se puede buscar otra función que permitiera separar mejor las clases.
- Representación gráfica de la clasificación multiclase: una de las mayores desventajas de la librería Libsvm es la dificultad de representar las fronteras de decisión en un gráfico. Una herramienta capaz de representarlo nos permitiría modificar las variables de la función núcleo más fácilmente.
- Automatización del proceso: las herramientas de la librería Libsvm son muy rígidas y no permiten que se les introduzca variables como el tipo de función núcleo o el valor del margen blando a través de otras variables generadas en un programa.

7. Bibliografía

- [1] H. Li, L. Fu, and H. Zheng. Bearing fault diagnosis based on amplitude and phase map of Hermitian wavelet transform. *Journal of Mechanical Science and Technology* 25 (11):2731–2740, 2011.
- [2] S. Braun. *Discovering signal processing: an interactive guide for engineers*. John Wiley & Sons, 2008.
- [3] L.H. Chiang, E.L. Russell and R.D. Braatz. *Fault Detection and Diagnosis in Industrial Systems*. Springer, 2001.
- [4] Vicente Capistrán Gómez, Rodrigo Iván Paredes Portador. “Diagnóstico de condiciones de operación de rodamientos en máquinas usando espectros de alto orden”, tesis de grado, Centro Nacional de investigación y desarrollo tecnológico (CENIDET), Cuernavaca, Morelos, Marzo 2005.
- [5] Gao,R.X;Yan,R. *Theory and Applications for Manufacturing*. Springer 2011.
- [6] HAAR, A. “Zur Theorie der Orthogonalen Funktionen-systeme”. *Mathematics Analysis*. 1910. Vol. 69, p. 331-371
- [7] A. Jensen and A. la Cour-Harbo. *Ripples in Mathematics*. Springer, 2000
- [8] S. Mallat. A theory for multiresolution signal decomposition: The wavelet representation. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, volume 11(7), pages 674–693, 1989.
- [9] DAUBECHIES, I. "Orthonormal Bases of Compactly Supported Wavelets". *Communication in Pure and Applied Mathematics*. 1988. Vol. 41, No. 7, p. 909-996.
- [10] V. Riobó Otero. “Reconocimiento de localizaciones mediante máquinas de soporte vectorial”. Proyecto fin de carrera. Universidad Carlos III de Madrid. 2012.
- [11]J. Muñoz Pérez. *Inteligencia Computacional inspirada en la vida*. Universidad de Málaga. Servicio de publicaciones e intercamb.2010
- [12] O. Lara. “Nuevas metodologías no invasivas de diagnosis de defectos incipientes en rodamientos de bola”. Tesis doctoral. Universidad Carlos III de Madrid, 2007.
- [13]M.J. Gómez García. *Metodologías de selección de indicadores óptimos para el análisis y diagnosis del estado de la máquina: aplicación a elementos mecánicos rotativos*. Tesis doctoral. Universidad Carlos III de Madrid. 2014.
- [14]O. Lara. “Identificación de la condición de rodamientos de bola a través del cálculo de energía wavelet y redes neuronales artificiales”. Proyecto fin de carrera. Universidad Carlos III de Madrid. 2010.

- [15] Neural Network Framework. www.redes-neuronales.com.es (Última visita 09/06/2015)
- [16] G. Colmenares. Inteligencia artificial. Apuntes de del curso (Postgrado en Economía): Análisis Multivariante y Aplicaciones. Parte 5.
<http://www.webdelprofesor.ula.ve/economia/gcolmen/postgrado2.html> (Última visita 09/06/2015)
- [17] E. Gutiérrez Alonso. "Aplicación de las máquinas de soporte vectorial para el reconocimiento de matrículas". Proyecto fin de carrera. Universidad Pontificia de Comillas. 2007.
- [18] H. Cisneros Carrillo. "Conversión de texto manuscrito a formato digital utilizando máquinas de soporte vectorial." Proyecto fin de Máster. Instituto Politécnico Nacional. Méjico. 2007.
- [19] M. Zamorano Castaño. "Análisis de señales mediante STFT y Wavelet. Aplicación a defectología en rodamientos". Proyecto fin de carrera. Universidad Carlos III de Madrid. 2010.
- [20] I. Martinez Aldana. "Detección de fallos en rodamientos mediante análisis de energía y lógica difusa". Proyecto fin de carrera. Universidad Carlos III de Madrid. 2009.
- [21] C.J. Lin, C.W. Hsu, C.C. Chang A practical guide to support vector classification Technical Report, Department of Computer Science and Information Engineering, National Taiwan University (2003)
- [22] Bering Data Center. Case Western reserve University.
<http://csegroups.case.edu/bearingdatacenter/home> (Última visita 09/06/2015)
- [23] M.J. Gómez, C. Castejón, and J.C. García-Prada. "Incipient fault detection in bearings through the use of WPT energy and neural networks". Advances in Condition Monitoring of Machinery in Non-Stationary Operations. Lecture Notes in Mechanical Engineering 2014, pp 63-72.
- [24] C. Castejón, O. Lara, J.C. García-Prada. "Automated diagnosis of rolling bearings using MRA and neural networks". Mechanical Systems and Signal Processing (Impact Factor: 2.47). 01/2010;
- [25] Apuntes de la asignatura "Elementos de máquinas y vibraciones". Universidad de Navarra.
http://www.imac.unavarra.es/web_imac/pages/docencia/asignaturas/emyv_documentacion.html (Última visita 09/06/2015)
- [26] LIBSVM -- A Library for Support Vector Machines.
www.csie.ntu.edu.tw/~cjlin/libsvm/ (Última visita 09/06/2015)
- [27] Kamalina Srikant. "Mejore la estrategia de mantenimiento gracias a la monitorización del estado de funcionamiento en línea." RedWeb. National Instruments. . 10/03/2015. Disponible online http://www.redeweb.com/ficheros/articulos/ni_318049622.pdf (Última visita 09/06/2015)

- [28] Servicio de mantenimiento Fuchs.
http://www.fuchs.es/fileadmin/fuchs_upload/industria/MANTENIMIENTO%20PREDICTIVO.pdf (Última visita 09/06/2015)
- [29] SKF condition monitoring products Webpage.
<http://www.skf.com/group/products/condition-monitoring/index.html?alias=www.skf.comfcm> (Última visita 09/06/2015)
- [30] Apuntes de la asignatura 'Elementos de máquinas'. Universidad Carlos III. 2010.
- [31] A. Statnikov1, C.F. Aliferis, I. Tsamardinos, D. Hardin and S. Levy, A comprehensive evaluation of multcategory classification methods for microarray gene expression cancer diagnosis. *Bioinformatics* (2005) 21 (5): 631-643.
- [32] Scikits Learn: 3.2. Support Vector Machines. Disponible online <http://scikit-learn.org/0.11/modules/svm.html>. (Última visita 09/06/2015)

8. ANEXOS

8.1. Anexo 1. Comparación de señales mediante la FFT

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.

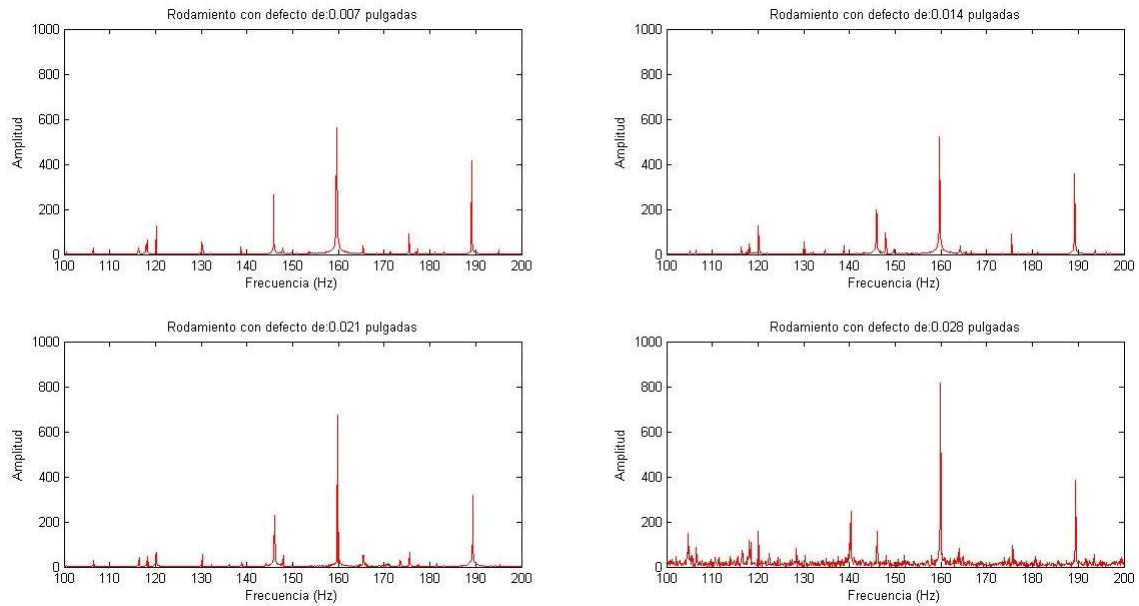


Figura A1.1. FFT de señales con defecto en bola, frecuencia característica de fallo 139,19 Hz

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.

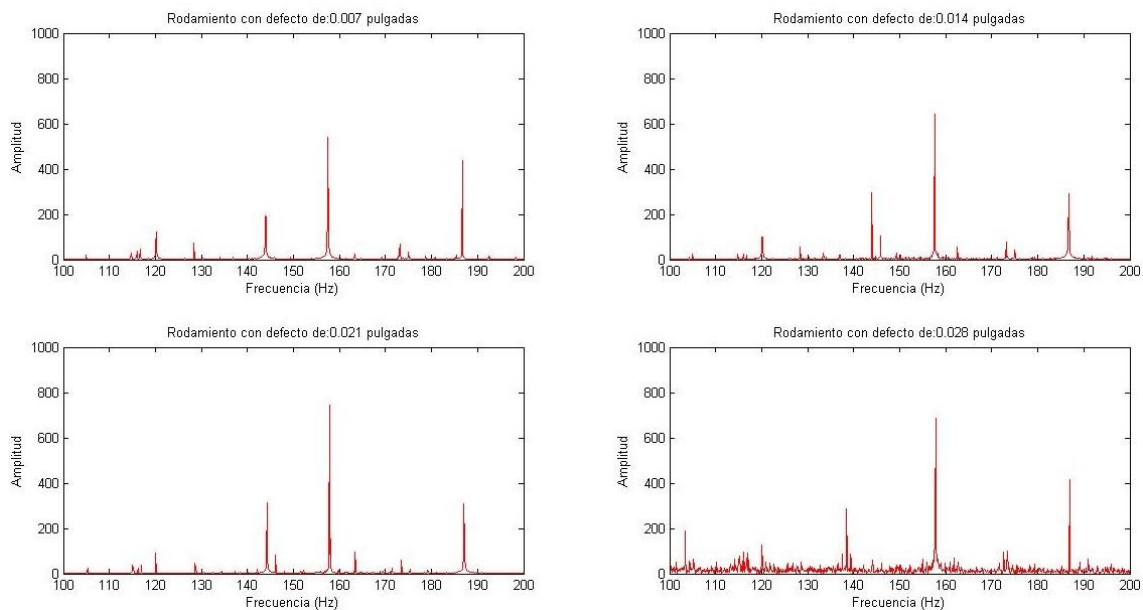


Figura A1.2. FFT de señales con defecto en bola, frecuencia característica de fallo 137,26 Hz

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.

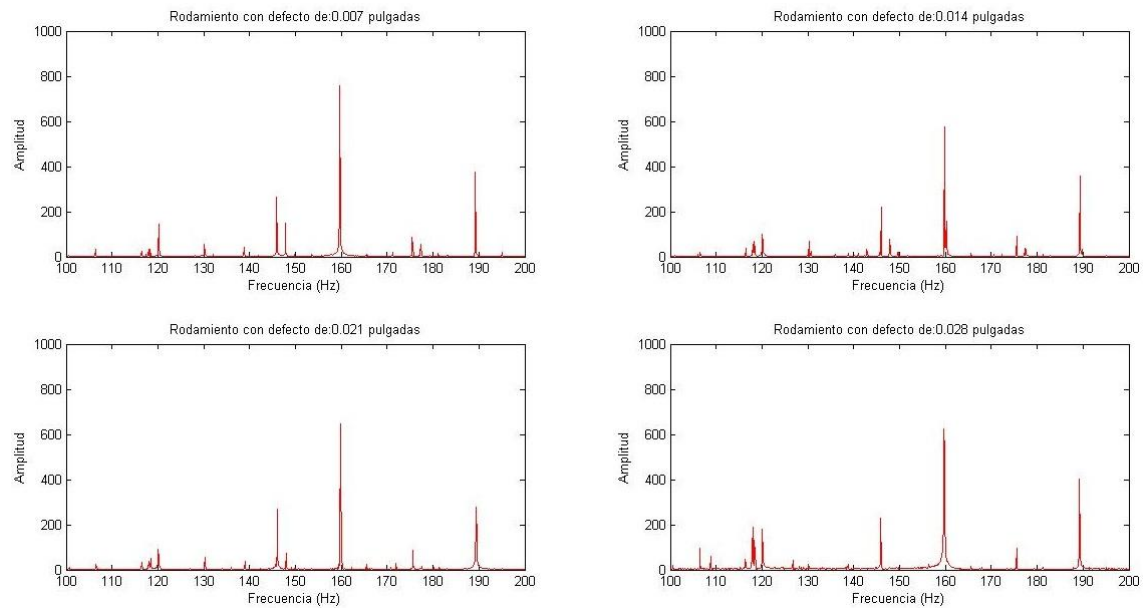


Figura A1.3. FFT de señales con defecto en pista interna, frecuencia característica de fallo 159,91 Hz

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.

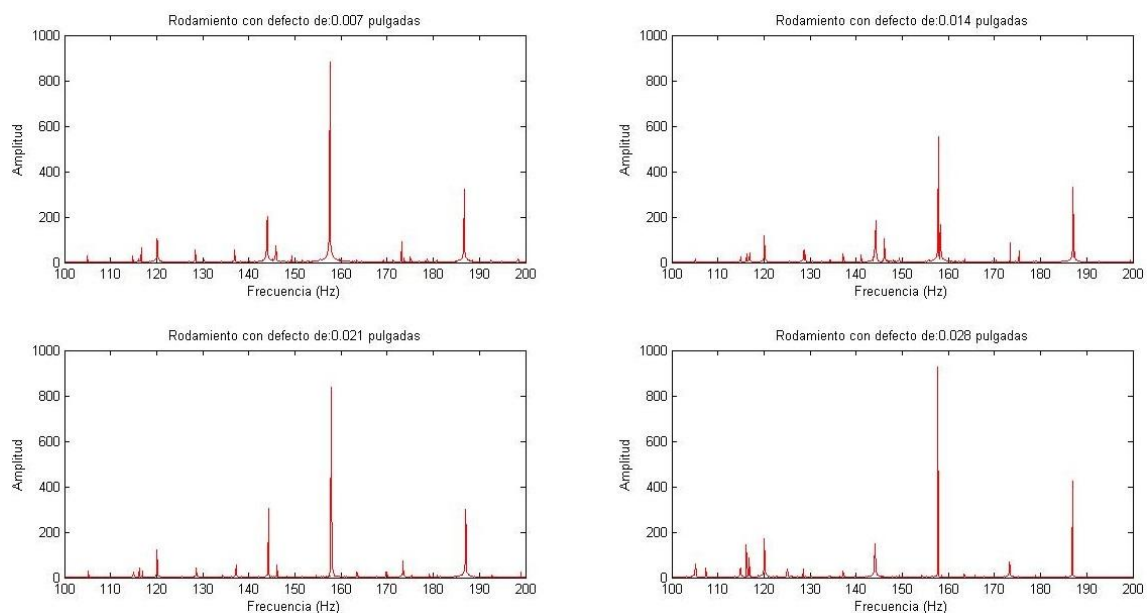


Figura A1.4. FFT de señales con defecto en pista interna, frecuencia característica de fallo 157,69 Hz

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.

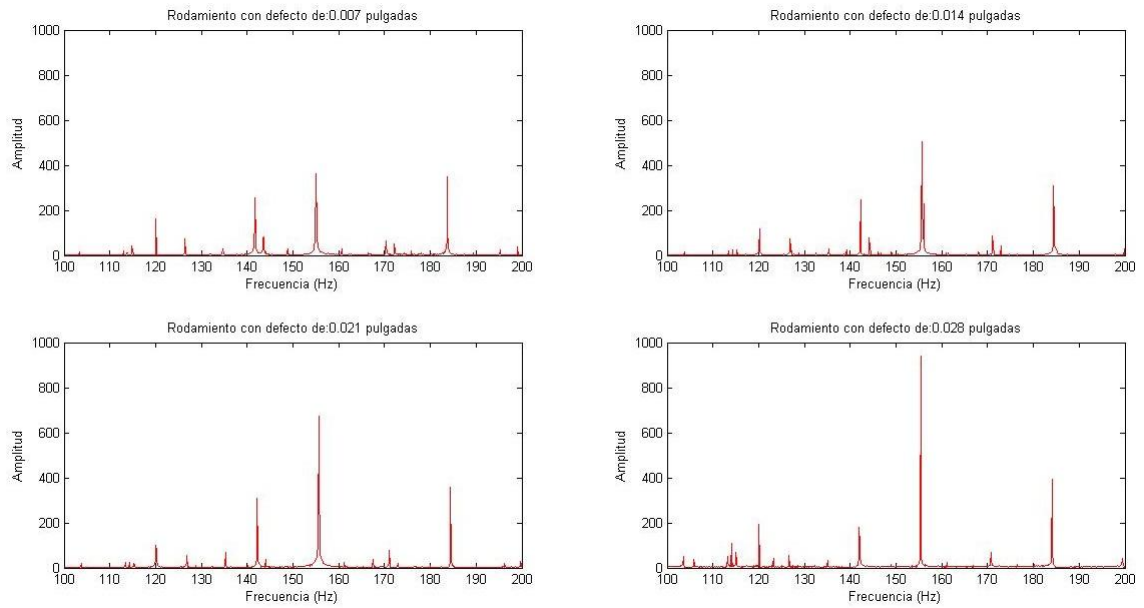


Figura A1.5. FFT de señales con defecto en pista interna, frecuencia característica de fallo 156,12 Hz

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.

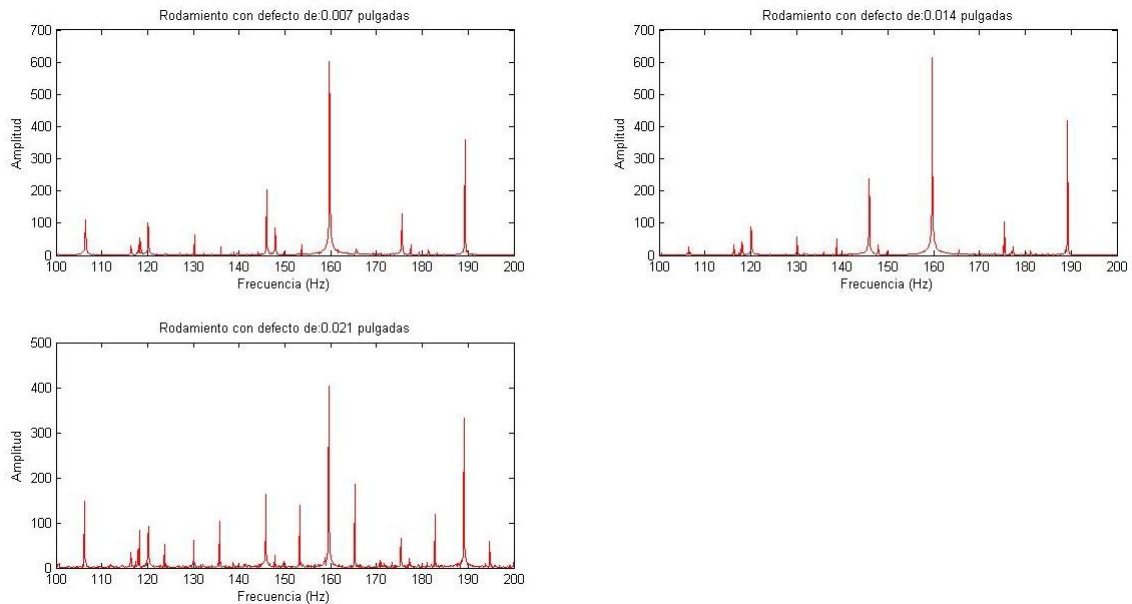


Figura A1.6. FFT de señales con defecto en pista externa, frecuencia característica de fallo 105,86 Hz

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.

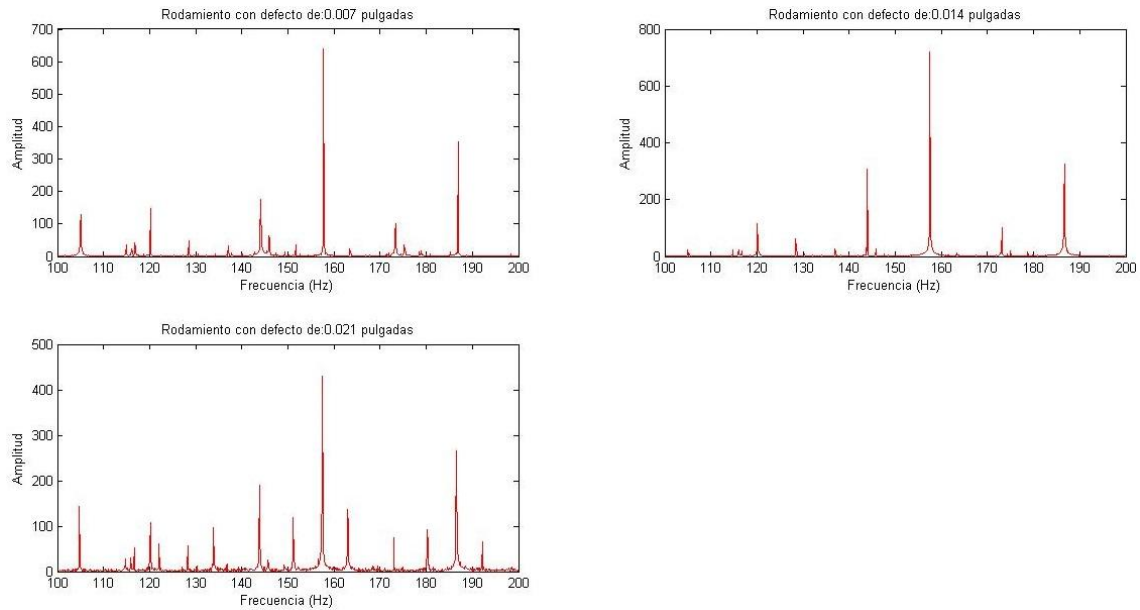


Figura A1.7. FFT de señales con defecto en pista externa, frecuencia característica de fallo 104,39 Hz

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.

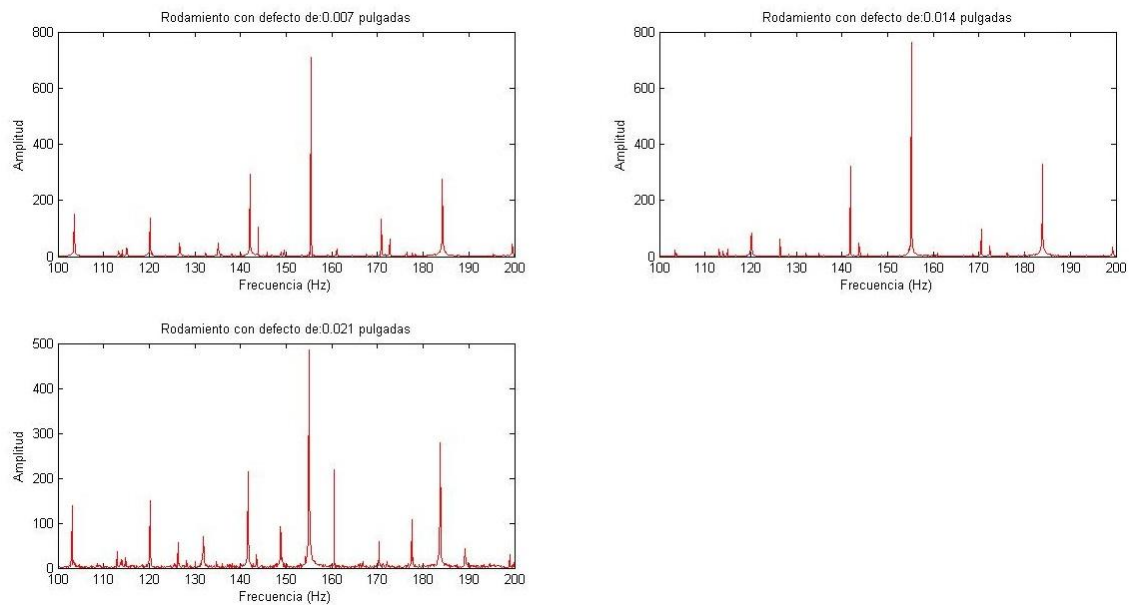


Figura A1.8. FFT de señales con defecto en pista externa, frecuencia característica de fallo 103,35 Hz

8.2. Anexo 2. Comparación de señales mediante la HT

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.

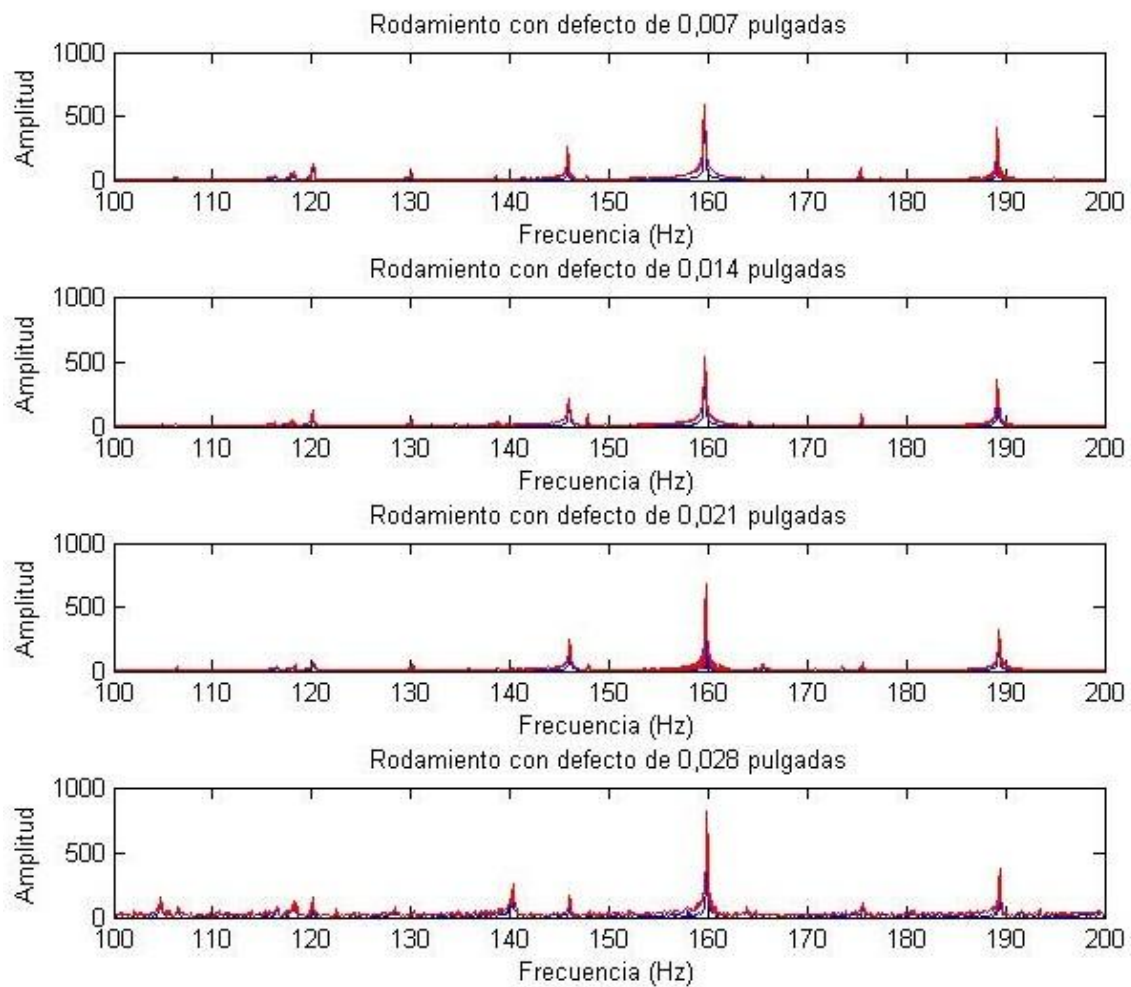


Figura A2.1. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.

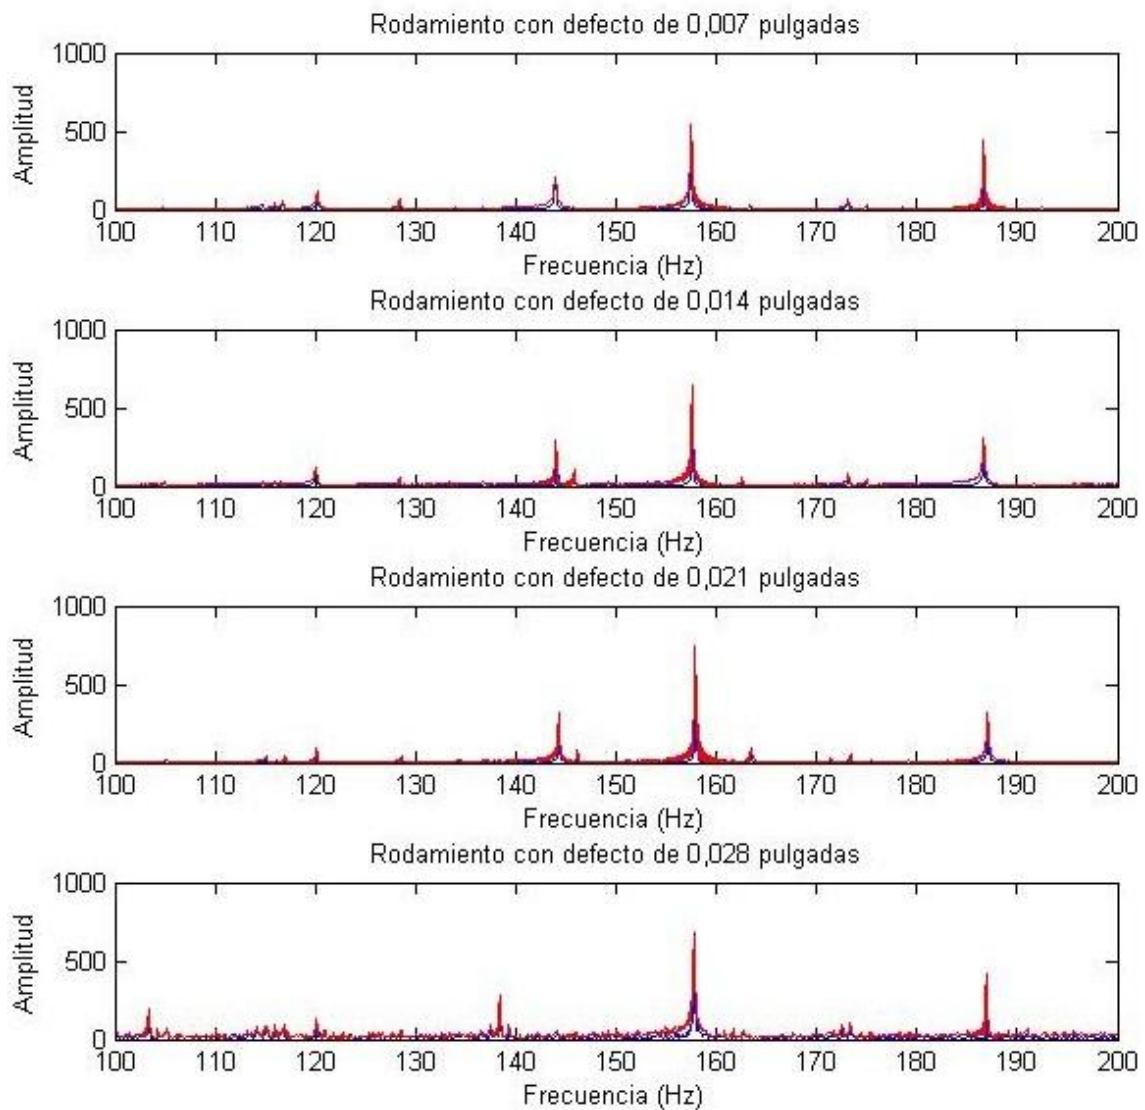


Figura A2.2. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en bola, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.

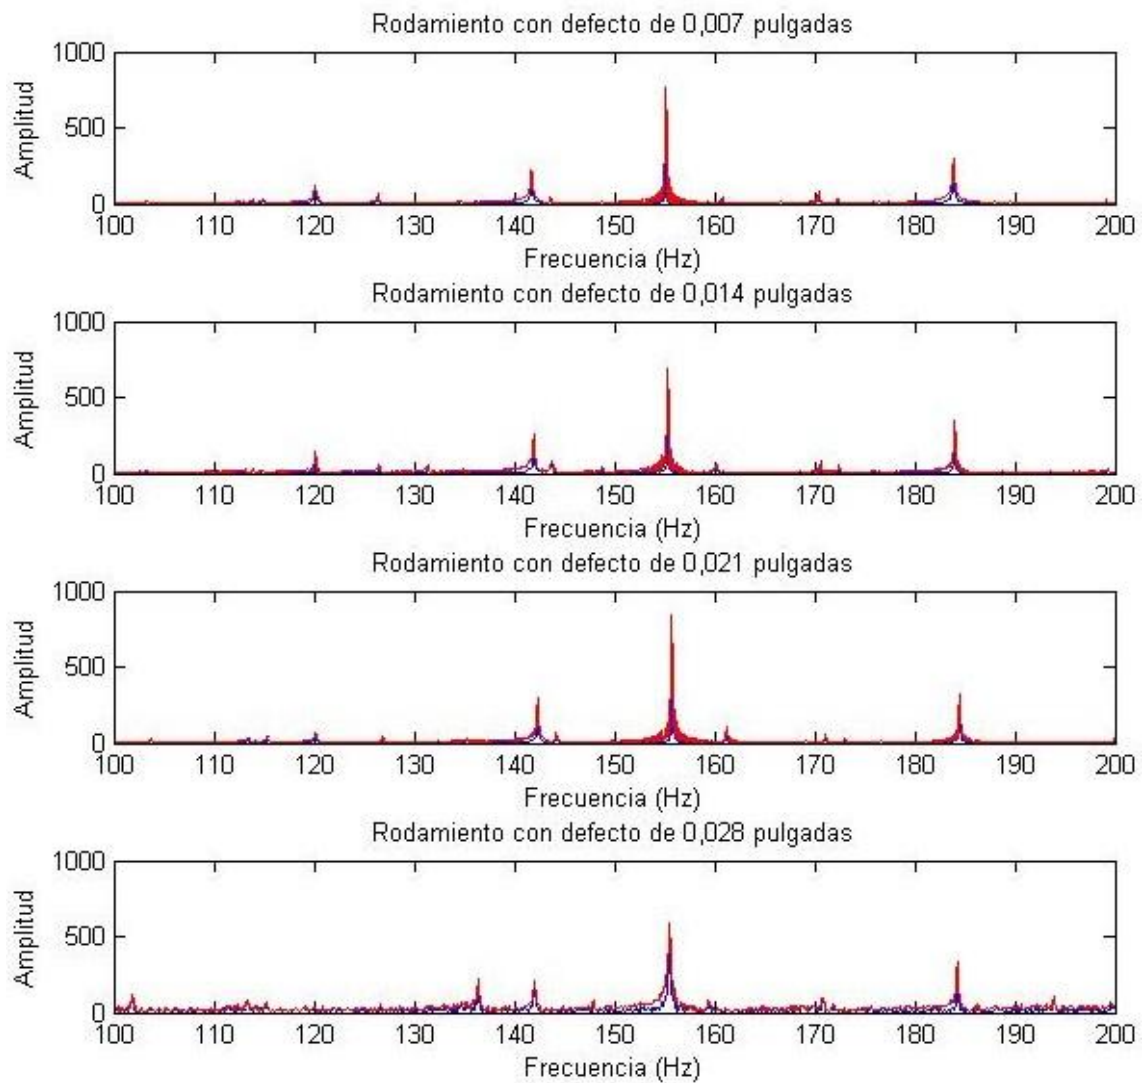


Figura A2.3. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.

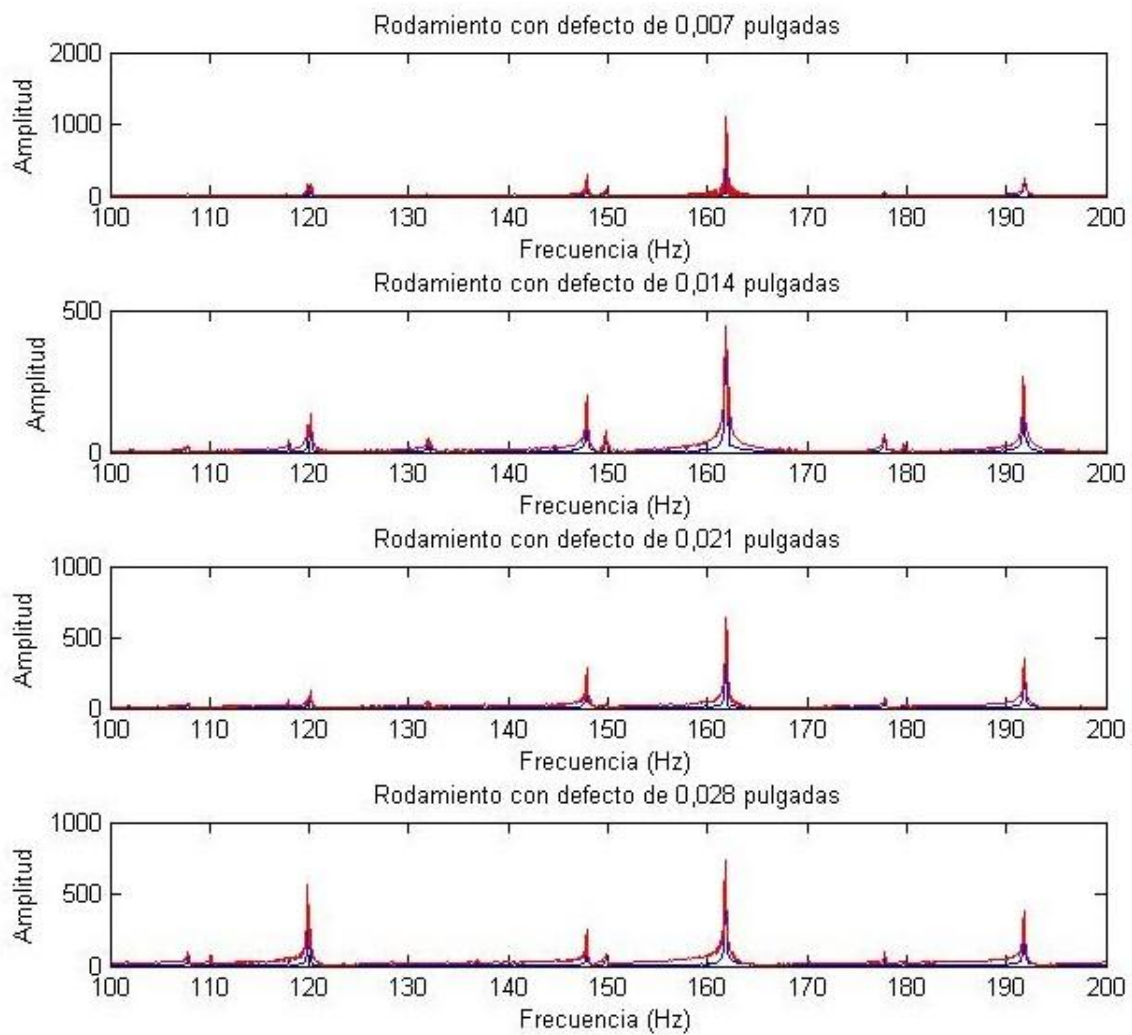


Figura A2.4. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.




Figura A2.5. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.




Figura A2.6. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista interna, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.

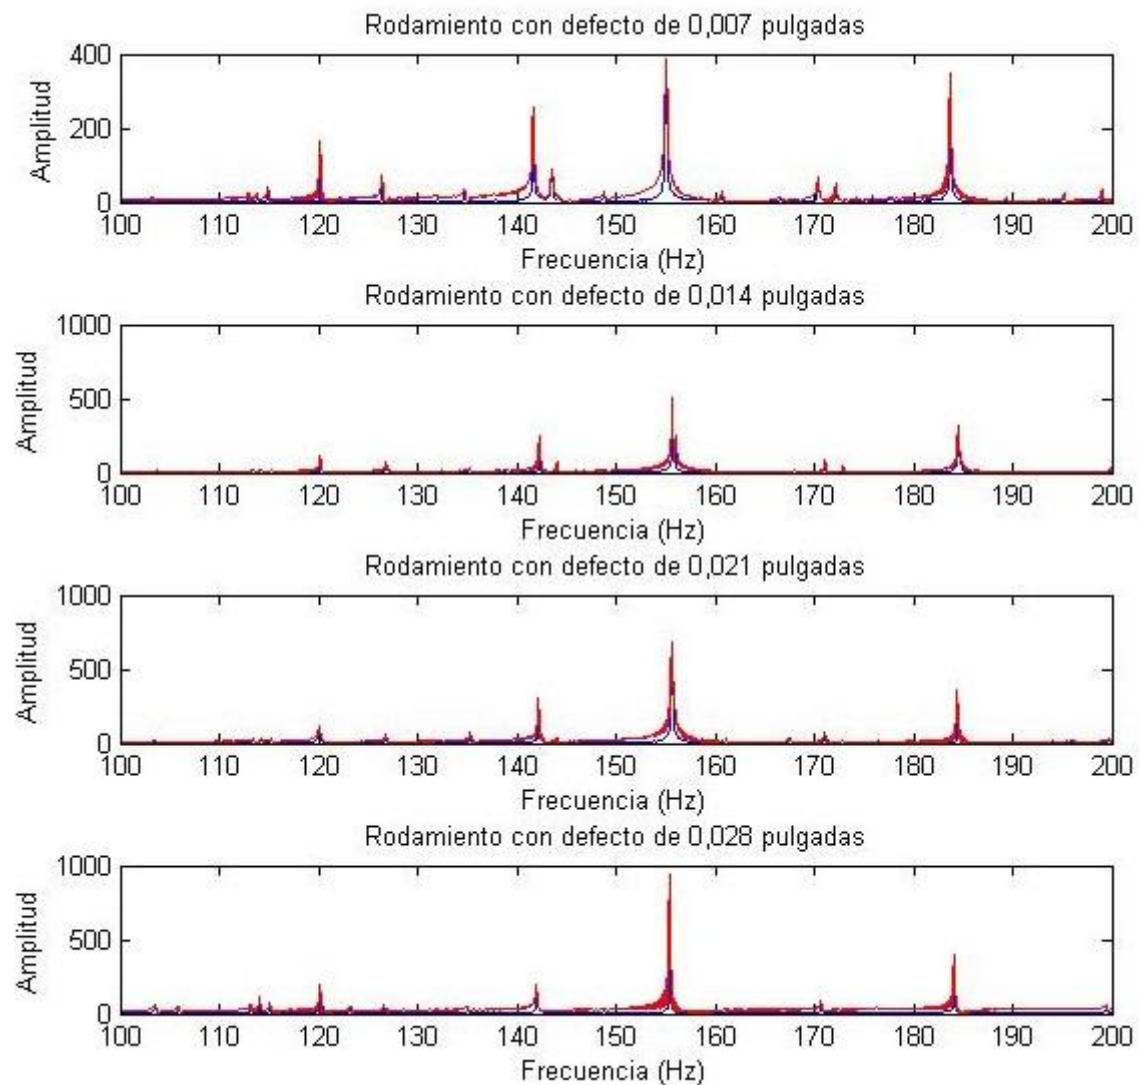


Figura A2.7. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1797rpm (29,95 Hz) y distintos tamaños de defecto.

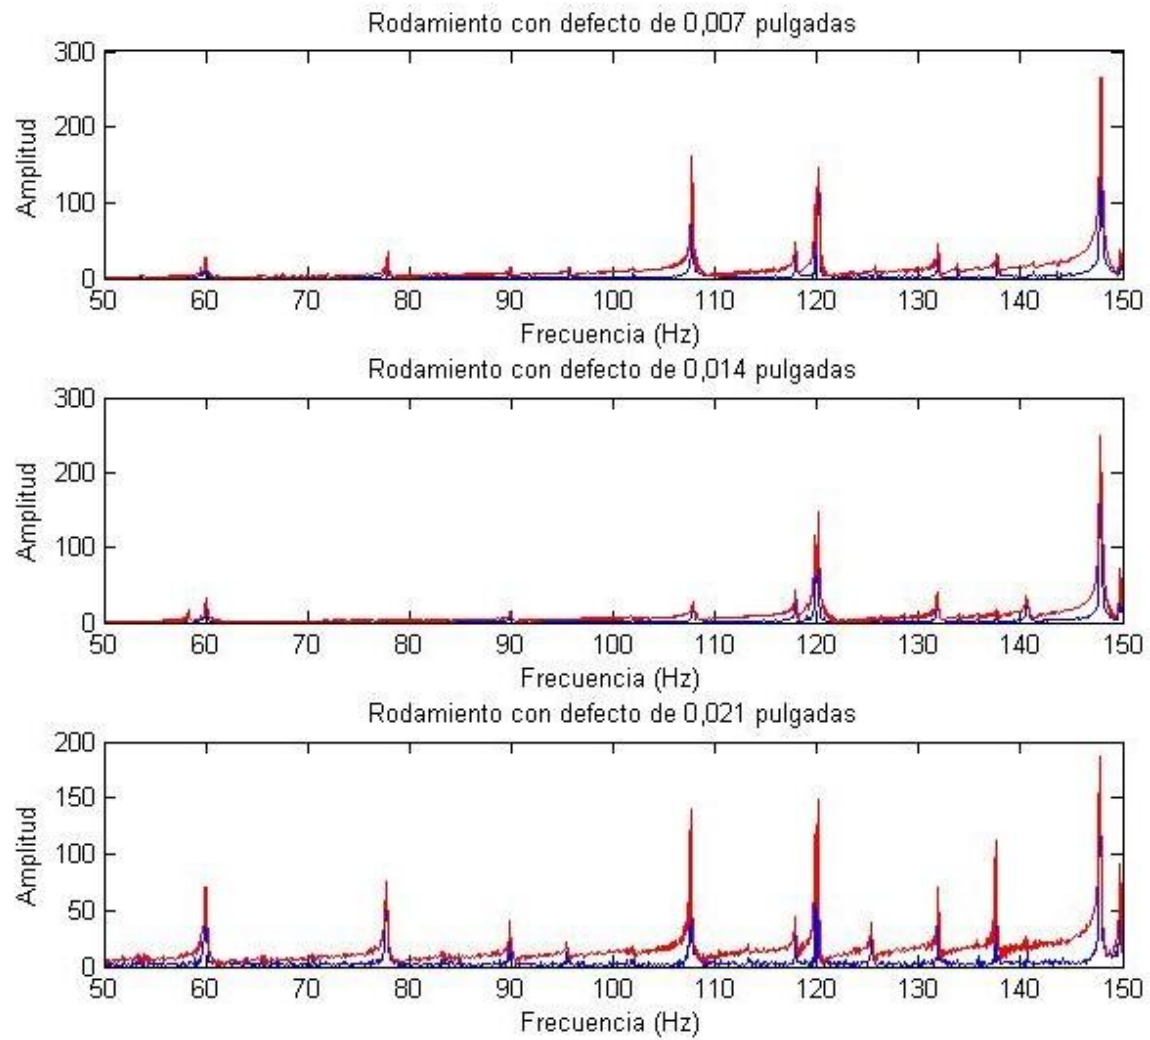


Figura A2.8. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1772rpm (29,53 Hz) y distintos tamaños de defecto.

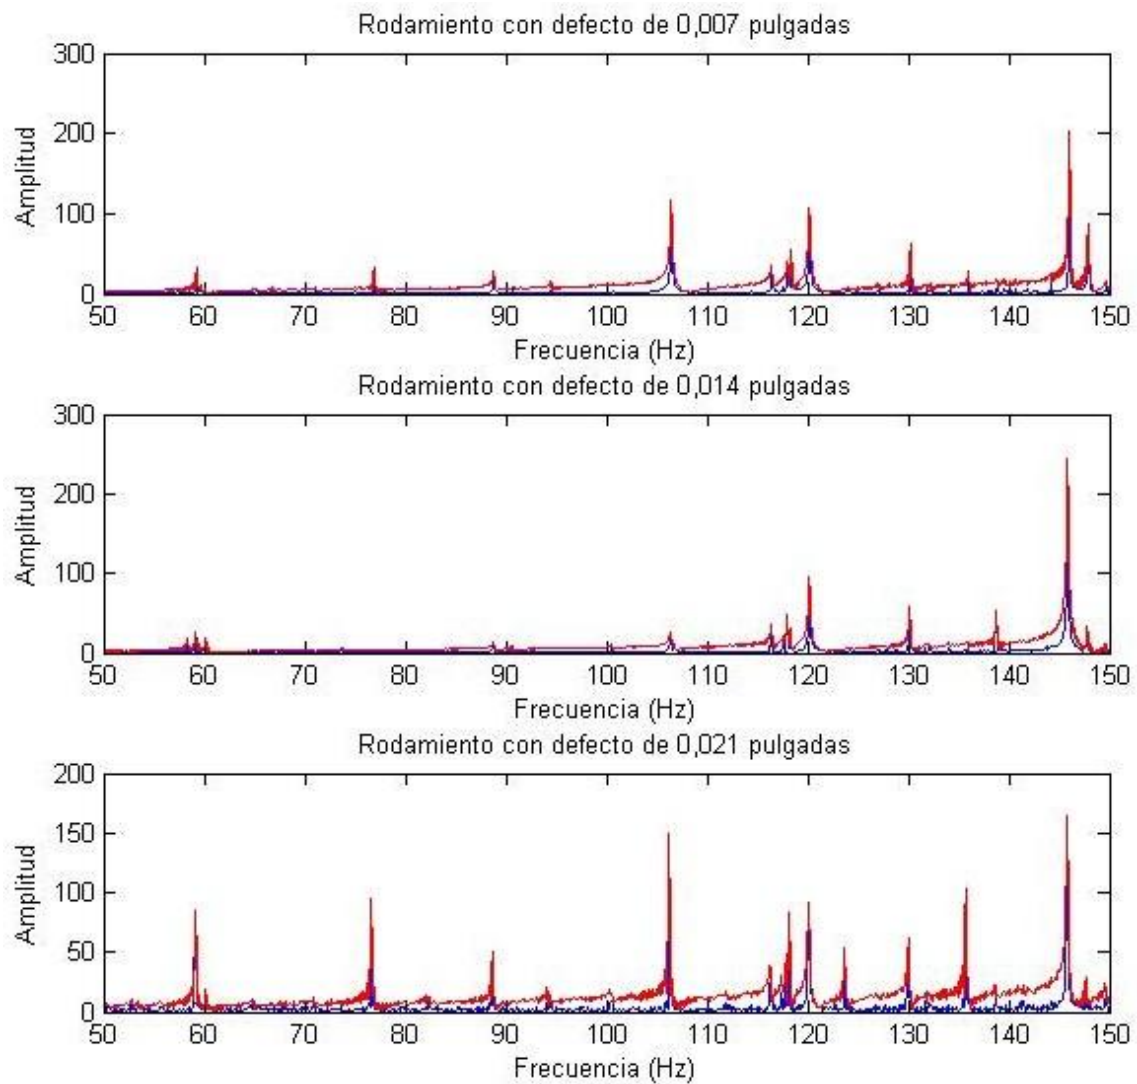


Figura A2.9. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1750rpm (29,17 Hz) y distintos tamaños de defecto.

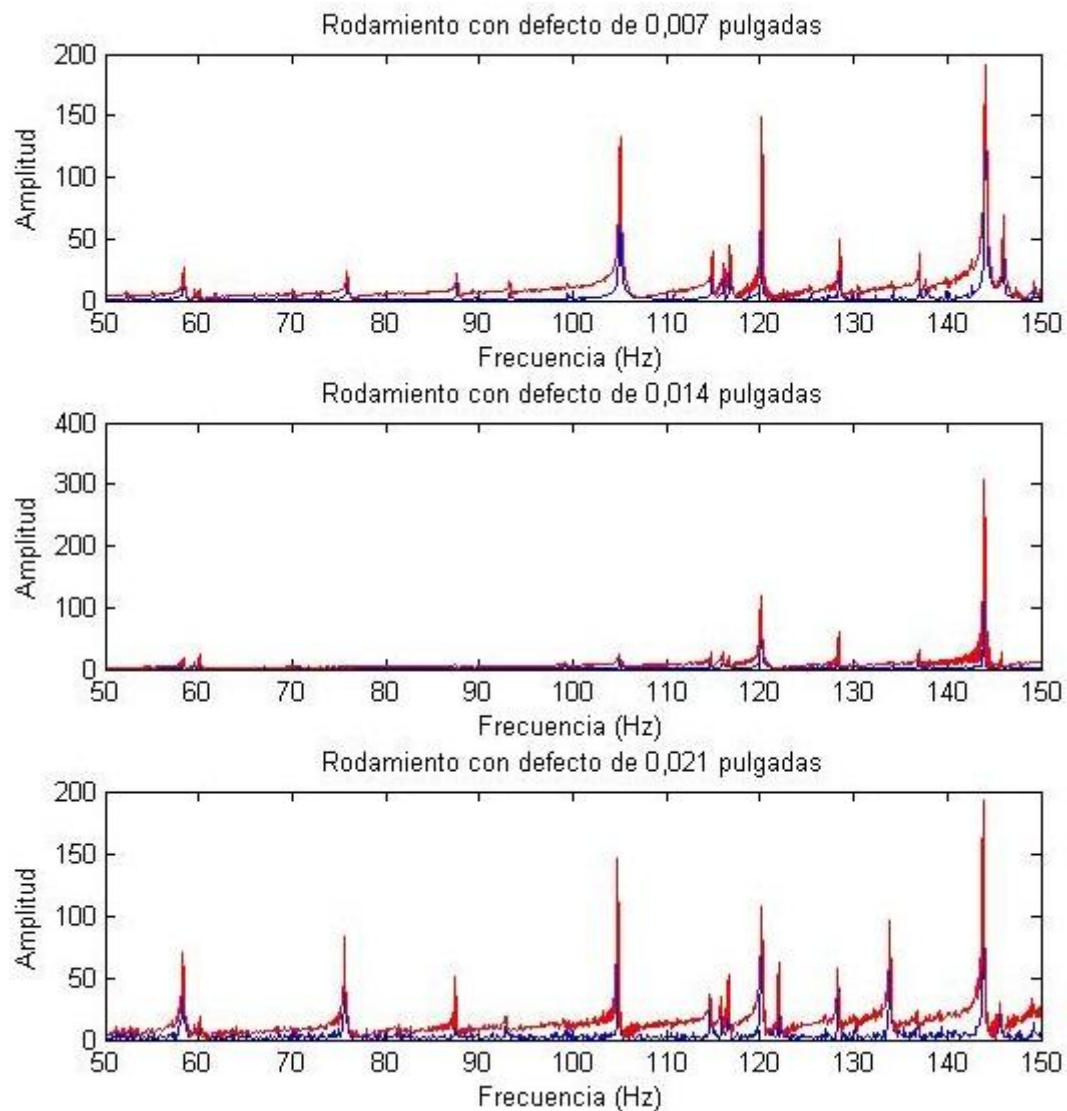


Figura A2.10. Envolvente de la señal mediante la aplicación de la HT.

- Comparación de señales de rodamiento con defecto en pista externa, para una misma velocidad de giro de 1730rpm (28,83 Hz) y distintos tamaños de defecto.




Figura A2.11. Envolvente de la señal mediante la aplicación de la HT.

8.3. Anexo 3. Descomposición mediante la WPT

- Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 7 de descomposición.

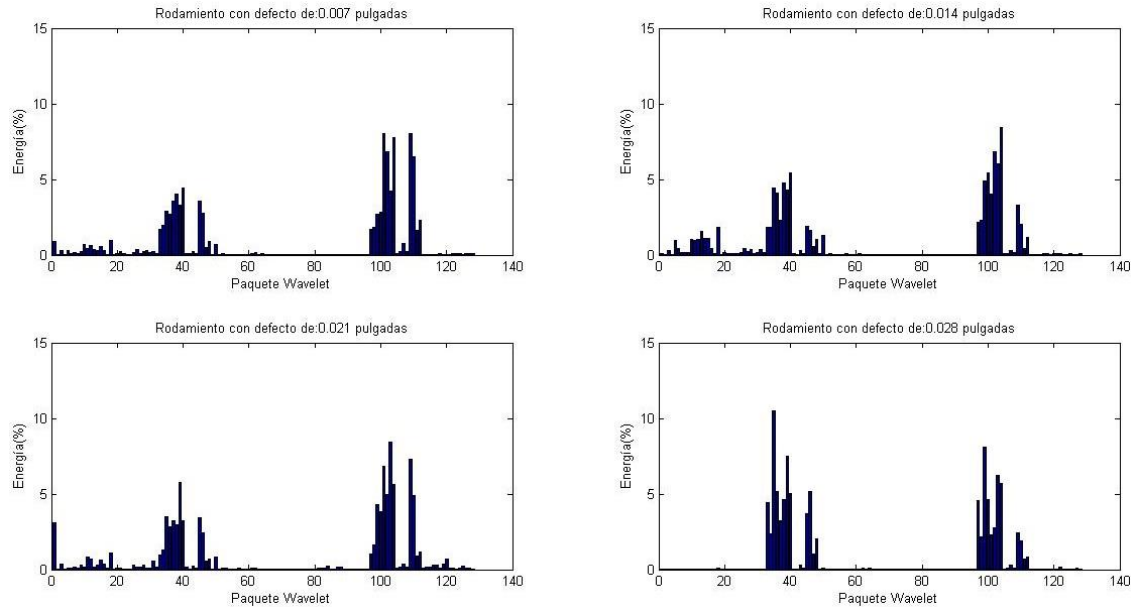


Figura A3.1. WPT con nivel de descomposición 7 para señal con defecto en bola

- Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 6 de descomposición.

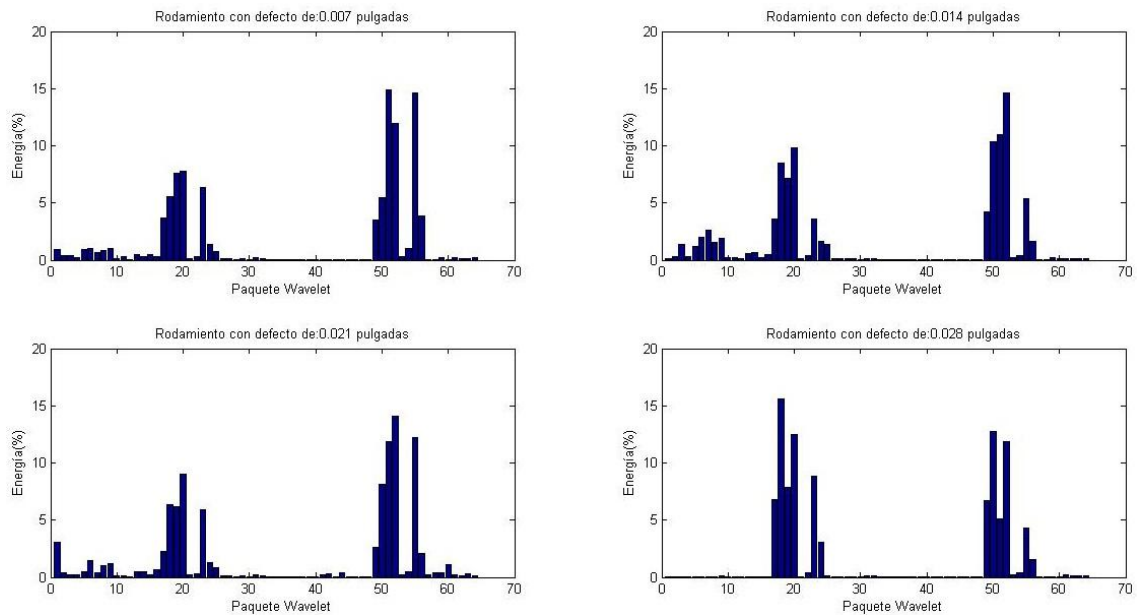


Figura A3.2. WPT con nivel de descomposición 6 para señal con defecto en bola

- Comparación de señales de rodamientos con defecto en bola y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 4 de descomposición.

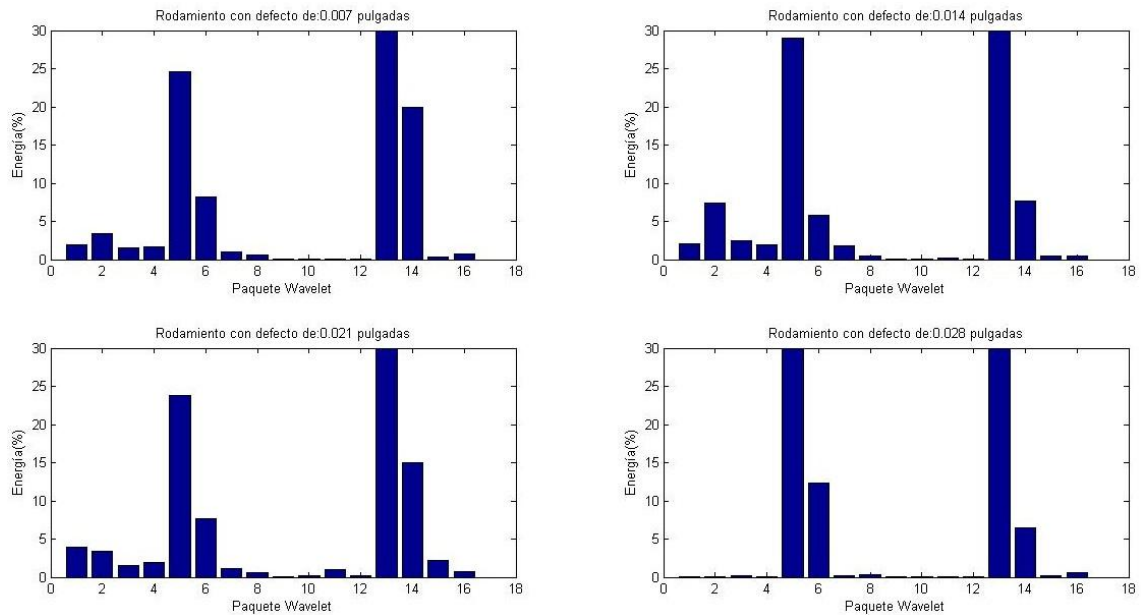


Figura A3.3. WPT con nivel de descomposición 4 para señal con defecto en bola

- Comparación de señales de rodamientos con defecto en pista interna y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 3 de descomposición.




Figura A3.4. WPT con nivel de descomposición 3 para señal con defecto en pista interna

- **Comparación de señales de rodamientos con defecto en pista externa y distinto tamaño de defecto para una misma velocidad de giro, aplicando WPT con nivel 3 de descomposición.**

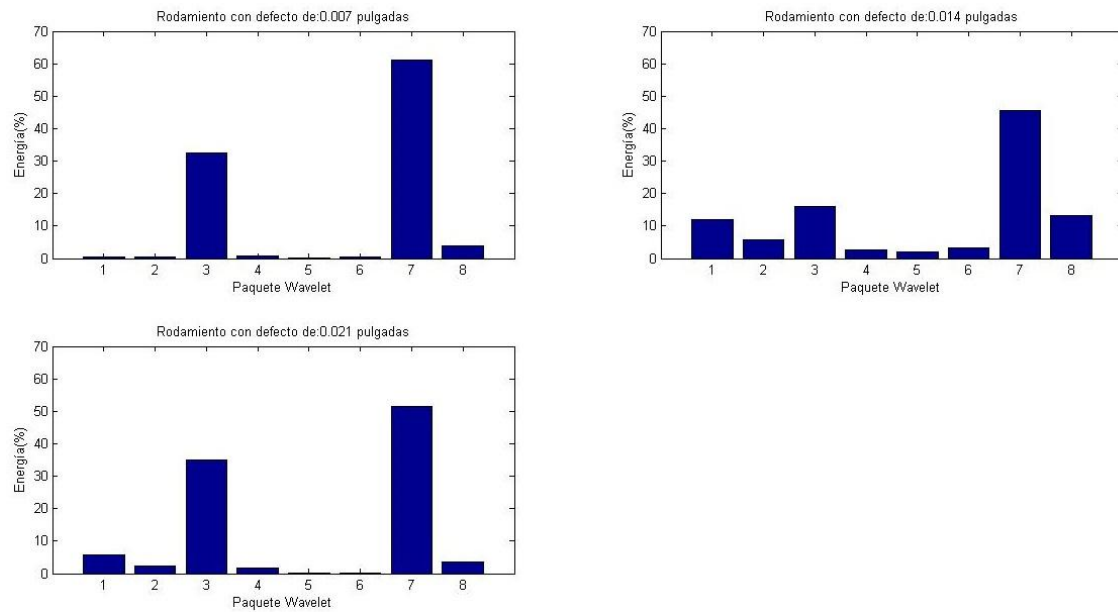


Figura A3.5. WPT con nivel de descomposición 3 para señal con defecto en pista externa

8.4. Anexo 4. Gráficos de precisión en función de los valores de los parámetros Gamma y C para señales de rodamientos con defectos incipientes.

- Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 600 rpm.




Figura A4.1. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 600 rpm.




Figura A4.2. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 600 rpm.




Figura A4.3. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento con defecto en pista externa para velocidad de giro de 600 rpm.




Figura A4.4. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en pista externa y rodamiento con defecto en pista interna para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento sano para velocidad de giro de 600 rpm.




Figura A4.5. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista interna para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en pista externa y rodamiento sano para velocidad de giro de 600 rpm.




Figura A4.6. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista externa para velocidad de giro de 600 rpm.

- Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 1200 rpm.




Figura A4.7. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 1200 rpm

- Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 1200 rpm.




Figura A4.8. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 1200 rpm

- Entrenando con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 1200 rpm.




Figura A4.9. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 1200 rpm.

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento con defecto en pista externa para velocidad de giro de 1200 rpm.




Figura A4.10. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en pista interna y rodamiento con defecto en pista externa para velocidad de giro de 1200 rpm

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento sano para velocidad de giro de 1200 rpm.




Figura A4.11. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista interna para velocidad de giro de 1200 rpm.

- Entrenando con señales de rodamiento con defecto en pista externa y rodamiento sano para velocidad de giro de 1200 rpm.




Figura A4.12. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista externa para velocidad de giro de 1200 rpm.

- **Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 1800 rpm.**




Figura A4.13. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista externa para velocidad de giro de 1800 rpm

- **Entrenando con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 1800 rpm.**




Figura A4.14. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento con defecto en pista interna para velocidad de giro de 1800 rpm

- Entrenando con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 1800 rpm.




Figura A4.15. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en bola y rodamiento sano para velocidad de giro de 1800 rpm.

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento con defecto en pista externa para velocidad de giro de 1800 rpm.




Figura A4.16. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento con defecto en pista interna y rodamiento con defecto en pista externa para velocidad de giro de 1800 rpm

- Entrenando con señales de rodamiento con defecto en pista interna y rodamiento sano para velocidad de giro de 1800 rpm.




Figura A4.17. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista interna para velocidad de giro de 1800 rpm.

- Entrenando con señales de rodamiento con defecto en pista externa y rodamiento sano para velocidad de giro de 1800 rpm.




Figura A4.18. Representación mediante escala de colores de la precisión esperada al entrenar con señales de rodamiento sano y rodamiento con defecto en pista externa para velocidad de giro de 1800 rpm.

8.5. Anexo 5. Instalación de la librería Libsvm para MATLAB®.

La librería específica Libsvm consiste en un conjunto de funciones que permiten el uso de las máquinas de soporte vectorial de una manera sencilla e intuitiva. Toda la información acerca de quién la realizó y el tipo de análisis que permite, podemos encontrarlo en [26].

La versión empleada en el presente PFC es la 3.18, pero se ha probado con versiones anteriores que los pasos a seguir para su instalación y uso son los mismos.

La librería Libsvm está disponible para numerosos lenguajes de programación pero nos centramos únicamente en los códigos para MATLAB®.

INSTALACIÓN

Cuando descargamos la carpeta de [26], nos encontramos con lo siguiente:

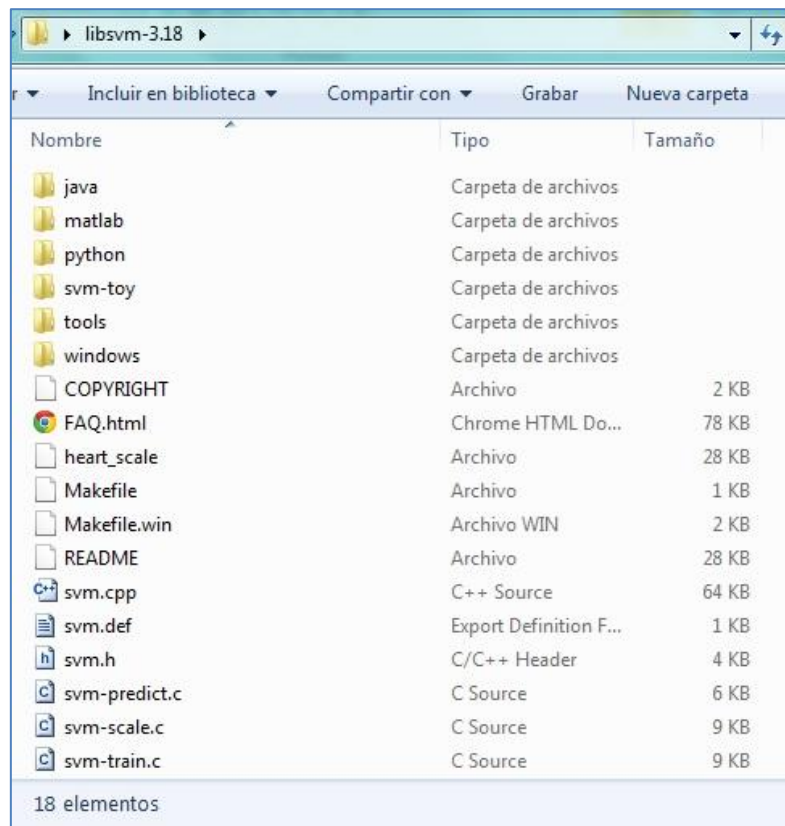


Figura A4.1. Contenido de la carpeta Libsvm 3.18

Como se puede observar, existe una carpeta con el nombre de MATLAB® que contiene los códigos para usar en éste entorno de programación. Cuando abrimos ésta carpeta nos encontramos lo siguiente:




Figura A4.2. Contenido de la carpeta matlab

Como podemos observar, todos los archivos tienen la extensión “.c” y que están programados para usar en C/C++, a excepción de “make.m” que sí tiene la extensión apropiada para usar en MATLAB®. Para poder utilizar tanto svmtrain como svmpredict necesitamos de un compilador que permita usar estas funciones programadas en C para MATLAB®. El propio programa de MATLAB®, contiene un compilador para dicha tarea pero se recomienda instalar Visual Studio en una de las versiones compatibles con la versión de MATLAB® que se esté utilizando (se puede consultar las versiones compatibles en el soporte en línea de mathworks).

Una vez descargada la librería e instalado Visual Studio, se procede a copiar la carpeta libsvm 3.18 (no sólo la carpeta con el nombre de matlab, puesto que hay archivos necesarios para la compilación fuera de la carpeta) en el directorio:

C:\Program Files\MATLAB\R*****\bin.

Una vez copiada la carpeta, se procede a añadir la librería a las utilizadas por MATLAB® mediante el comando Set Path...

Ahora utilizamos el comando Add with Subfolders... como se muestra en la figura A4.3. Para añadir la carpeta libsvm 3.18 la seleccionamos dentro de la nueva ventana que nos aparece como se muestra en la figura A4.4.

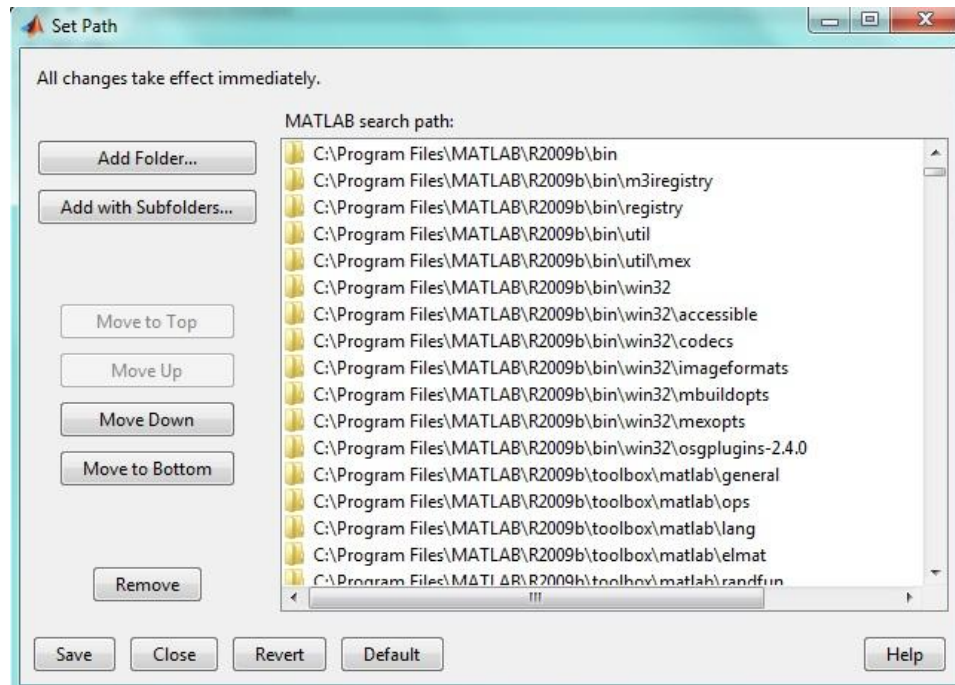


Figura A4.3. Ventana que se abre al seleccionar Set Path...



Figura A4.4. Ventana que se abre al seleccionar Add with Subfolders...

Una vez añadido el directorio, procedemos a la compilación de los programas para poder usarlos en MATLAB®.

Para ello, en el Command Window, introducimos el comando:

```
>>mex -setup
```

Obteniendo lo que se muestra en la figura A4.5.

```
>> mex -setup
Please choose your compiler for building external interface (MEX) files:

Would you like mex to locate installed compilers [y]/n?
```

Figura A4.5.

Introduciremos “y”, obteniendo lo que se muestra en la figura A4.6.

```
>> mex -setup
Please choose your compiler for building external interface (MEX) files:

Would you like mex to locate installed compilers [y]/n? y

Select a compiler:
[1] Lcc-win32 C 2.4.1 in C:\PROGRA~1\MATLAB\R2009b\sys\lcc
[2] Microsoft Visual C++ 2008 Express in C:\Program Files\Microsoft Visual Studio 9.0

[0] None














Compiler:
```

Figura A4.6.

Ahora introducimos un “2” para seleccionar el compilador Microsoft Visual Studio y nos pedirá de nuevo una confirmación de lo seleccionado. Introducimos de nuevo una “y” para responder que sí y el proceso habrá terminado.

Para verificar que la instalación se ha realizado correctamente debemos ir al directorio donde copiamos libsvm 3.18 y abrir la carpeta matlab.

Si se ha realizado correctamente se deberían haber generado unos archivos con extensión mexw32 como se muestra en la figura A4.7.

Nombre	Tipo	Tamaño
 Makefile	Archivo	2 KB
 README	Archivo	10 KB
 libsvmread.c	C Source	4 KB
 libsvmwrite.c	C Source	3 KB
 svm_model_matlab.c	C Source	9 KB
 svmpredict.c	C Source	10 KB
 svmtrain.c	C Source	12 KB
 svm_model_matlab.h	C/C++ Header	1 KB
 libsvmread.mexw32	MATLAB MEX-file	9 KB
 libsvmwrite.mexw32	MATLAB MEX-file	8 KB
 svmpredict.mexw32	MATLAB MEX-file	21 KB
 svmtrain.mexw32	MATLAB MEX-file	49 KB
 make.m	MATLAB M-file	1 KB

13 elementos

Figura A4.7.

